



**Rui Domingos de Sá Rodrigues**

Licenciado em Ciências da Engenharia Electrotécnica e de  
Computadores

**PREVISÃO DE CONSUMO DE ENERGIA DE CURTO-PRAZO (DIA  
SEGUINTE) COM RECURSO A WAVELETS**

Dissertação para obtenção do Grau de Mestre em  
Engenharia Electrotécnica e de Computadores

Orientador: Prof. Dr. João Murta Pina,  
Prof. Auxiliar, Universidade Nova de Lisboa

Júri:

Presidente: Dr. João Rosas

Arguente: Dr. João Martins

Vogais: Dr. João Martins  
Dr. João Pina



FACULDADE DE  
CIÊNCIAS E TECNOLOGIA  
UNIVERSIDADE NOVA DE LISBOA

**Junho, 2015**



**PREVISÃO DE CONSUMO DE ENERGIA DE CURTO-PRAZO (DIA SEGUINTE) COM RECURSO  
A WAVELETS**

Copyright © Rui Domingos de Sá Rodrigues, Faculdade de Ciências e Tecnologia, Universidade Nova de Lisboa.

A Faculdade de Ciências e Tecnologia e a Universidade Nova de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objectivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.



*Aos meus pais por toda a paciência que tiveram comigo.*



## AGRADECIMENTOS

Ao Departamento de Engenharia Electrotécnica da Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa e a todo o seu corpo docente por todo o conhecimento de excelência que me transmitiram ao longo do Mestrado Integrado em Engenharia Electrotécnica e de Computadores.

Ao professor João Murta Pina, por me ter orientado ao longo deste trabalho e que sempre mostrou total abertura em relação às minhas ideias e sempre me deu total liberdade para seguir o meu caminho e fazer as minhas escolhas.

Um agradecimento à empresa EDP Distribuição pela cedência de dados de consumo monitorizados, sem os quais teria sido impossível realizar este trabalho.

O sincero agradecimento aos meus pais, que mais uma vez demonstraram ser peças basilares ao longo de toda a minha vida académica, que agora se avizinha do fim.

Por fim, aos meus amigos, colegas de curso e companheiros de casa, que me acompanharam nesta jornada académica, pelo incentivo e apoio quando nem tudo corria pelo melhor.





## RESUMO

A actividade de produção de energia eléctrica, bem como o seu transporte e distribuição até aos consumidores finais iniciou-se no final do século XIX e, desde essa altura, o sector tem conhecido muitas transformações aos mais variados níveis. Mais recentemente, nas últimas décadas, o sector eléctrico tem enfrentado muitos desafios que têm contribuído bastante para o seu desenvolvimento e inovação.

A previsão de consumos de energia eléctrica é tradicionalmente importante para o equilíbrio entre a oferta e a procura, bem como para uma rigorosa gestão e planeamento das redes eléctricas de transporte e distribuição. A sua importância é ainda reforçada, actualmente, com a liberalização dos mercados energéticos, na medida que os comercializadores pretendem dispor de ferramentas que lhes permita estimar com precisão a curva de procura agregada de consumidores com quem contratualizam.

Os sistemas de previsão de carga podem ser classificados de acordo com o horizonte temporal, sendo regularmente divididos em três categorias: previsão a longo prazo; previsão a médio prazo; previsão a curto prazo.

Neste trabalho de dissertação, pretende-se desenvolver um sistema de previsão de consumo de energia para o dia seguinte (hora a hora) com o recurso a Wavelets, capaz de apresentar o consumo associado a cada período horário ao longo do dia. Para tal, foram desenvolvidos dois métodos que diferem entre si na forma como o conceito de Wavelets é aplicado na decomposição dos dados.

**Palavras-chave:** Energia eléctrica, Sector eléctrico, Previsão de consumo energia, Wavelets.



## ABSTRACT

The activity of production electrical energy as well as transportation and distribution until final consumers began in the late of 19<sup>th</sup> century and since then the sector has known a lot of transformations at many levels. More recently in the last decades the electric industry has seen very significant changes that lead to the innovation of the sector.

Load forecasting is not only fundamental to provide a balance between the supply and demand, but also valuable to the electric grid management and planning. The liberalization of this sector reinforces the importance of load forecasting because the different suppliers intend to employ useful tools to accurately estimate the aggregated load curve relative to their customers.

The load forecasting systems can be classified according to the time horizon, being regularly divided into three categories: long-term forecast; medium-term forecast; short-term forecast.

In this thesis we intend to develop a short term load forecasting system for the next day with the use of Wavelet able to present the consumption associated with each time period throughout the day. To this end, two methods have been developed that differ in how the Wavelet concept is applied in decomposition of data.

**Keywords:** Electrical energy, Energy sector, Short term load forecasting, Wavelet.



# CONTEÚDO

<b>AGRADECIMENTOS.....</b>	<b>VII</b>
<b>RESUMO .....</b>	<b>IX</b>
<b>ABSTRACT.....</b>	<b>XI</b>
<b>CONTEÚDO.....</b>	<b>XIII</b>
<b>LISTA DE FIGURAS .....</b>	<b>XVII</b>
<b>LISTA DE TABELAS .....</b>	<b>XXI</b>
<b>ABREVIATURAS E SÍMBOLOS .....</b>	<b>XXIII</b>
LISTA DE ABREVIATURAS.....	XXIII
LISTA DE SÍMBOLOS .....	XXV
<b>1 INTRODUÇÃO.....</b>	<b>1</b>
1.1 MOTIVAÇÃO E CONTEXTO.....	1
1.2 OBJECTIVOS PROPOSTOS .....	8
1.3 CONTRIBUTOS ORIGINAIS.....	9
1.4 ESTRUTURA DA DISSERTAÇÃO .....	9
<b>2 REVISÃO DA LITERATURA.....</b>	<b>11</b>
2.1 SISTEMA ELÉCTRICO NACIONAL .....	11
2.1.1 <i>Produção de Electricidade.....</i>	<i>13</i>
2.1.2 <i>Transporte de Electricidade .....</i>	<i>14</i>
2.1.3 <i>Distribuição de Electricidade.....</i>	<i>15</i>
2.1.4 <i>Comercialização de Electricidade.....</i>	<i>16</i>

2.1.5	<i>Operação dos Mercados de Electricidade</i> .....	17
2.1.6	<i>Logística na Mudança de Comercializador</i> .....	17
2.2	WAVELETS.....	18
2.2.1	<i>Percurso Histórico</i> .....	18
2.2.2	<i>Transformada de Wavelet</i> .....	19
2.2.3	<i>Wavelets na previsão de consumo de energia a curto prazo</i> .....	25
2.3	FACTORES QUE INFLUENCIAM A CURVA DE CARGA.....	28
2.4	MÉTODOS DE PREVISÃO DE CONSUMO .....	31
<b>3</b>	<b>ESTUDO DE CASO</b> .....	<b>35</b>
3.1	DADOS UTILIZADOS NA DISSERTAÇÃO .....	35
3.2	CARACTERIZAÇÃO DO LOCAL .....	36
3.3	ESTRUTURA DA REDE .....	38
3.4	FACTORES CONDICIONANTES DO DIAGRAMA DE CARGA.....	39
3.4.1	<i>Temperatura</i> .....	40
3.4.2	<i>Tipo de dia da semana</i> .....	42
<b>4</b>	<b>MODELOS DE PREVISÃO PROPOSTOS</b> .....	<b>43</b>
4.1	FERRAMENTAS UTILIZADAS.....	43
4.2	ESTRUTURA DAS VARIÁVEIS DE ENTRADA DO SISTEMA DE PREVISÃO .....	43
4.3	MODELOS DE PREVISÃO PROPOSTOS .....	45
4.3.1	<i>Primeiro modelo de previsão</i> .....	45
4.3.2	<i>Segundo modelo de previsão</i> .....	48
4.3.3	<i>Algoritmos de previsão</i> .....	50
4.4	SIMULAÇÕES E RESULTADOS .....	54
4.4.1	<i>Primeiro modelo de previsão</i> .....	55
4.4.2	<i>Segundo modelo de previsão</i> .....	61
4.4.3	<i>Comparação entre os modelos desenvolvidos</i> .....	66
<b>5</b>	<b>CONCLUSÕES E TRABALHO FUTURO</b> .....	<b>69</b>
5.1	CONCLUSÕES .....	69
5.2	TRABALHO FUTURO.....	70

<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>73</b>
<b>ANEXOS .....</b>	<b>79</b>
ANEXO 1: ILUSTRAÇÃO DOS TIPOS DE WAVELETS.....	79
ANEXO 2: CÓDIGO MATLAB DA TWD.....	81
ANEXO 3: CÓDIGO MATLAB DA APROXIMAÇÃO DE WAVELET.....	81
ANEXO 4: CÓDIGO MATLAB DO ALGORITMO DE PREVISÃO MAX TEMPERATURA.....	81
ANEXO 5: CÓDIGO MATLAB DO ALGORITMO DE PREVISÃO MIN TEMPERATURA.....	82
ANEXO 6: CÓDIGO MATLAB DO ALGORITMO DE PREVISÃO MAX_MIN TEMPERATURA.....	82





## LISTA DE FIGURAS

Figura 1.1: Pontas de consumo na Rede Nacional de Transporte (RNT) e na Rede Pública em 2013 (REN, 2014a).....	2
Figura 1.2: Evolução do Consumo de Energia em Portugal (REN, 2014b).....	3
Figura 1.3: Esquema com a importância dos sistemas de previsão no domínio dos sistemas de distribuição (Santos, 2005).....	4
Figura 1.4: Previsão de consumo e consumo efectivo em tempo real, a nível nacional, da REN (“REN - Eletricidade,” 2015) .....	5
Figura 1.5: Previsão do consumo eléctrico diário, a nível nacional, da REN (“Previsão de consumo diário,” 2015) .....	5
Figura 1.6: Curvas agregadas típicas da relação entre a procura/oferta nos mercados de energia eléctrica (Sousa, 2013).....	7
Figura 1.7: Valores de energia no MIEBL (“Mercado REN,” 2015) .....	7
Figura 2.1: Actividades fundamentais do SEN (Mourão, 2012) .....	12
Figura 2.2: Energia produzida por tipo de central (REN, 2014a).....	13
Figura 2.3: Emissão de PRE relativa a 2013 (REN, 2014a) .....	14
Figura 2.4: Síntese dos principais equipamentos da RNT (REN, 2014a) .....	14
Figura 2.5: Esquema geral do SEN (EDP, 2011a).....	15
Figura 2.6: Fluxo energético desde o produtor até ao consumidor (EDP, 2011b) .....	16
Figura 2.7: Características da RND (EDP, 2013) .....	16
Figura 2.8: Comparação gráfica das transformadas (G. S. Andrade, 2009) .....	20

Figura 2.9: Comparação entre Transformada de Wavelet e Fourier (Nava, 2006) .....	20
Figura 2.10: Diferentes tipos de wavelets (Misiti, Poggi, Misiti, & Oppenheim, 2013).....	21
Figura 2.11: Representação de um sinal em diferentes escalas e posições (Misiti, Poggi, Misiti, & Oppenheim, 2001).....	22
Figura 2.12: Decomposição de wavelet discreta (Misiti et al., 2001) .....	23
Figura 2.13: Esquema da árvore de decomposição wavelet (Misiti et al., 2001) .....	23
Figura 2.14: Processo de aumentar o número de amostras (Misiti et al., 2001) .....	24
Figura 2.15: Processo de decomposição e reconstrução do sinal (Misiti et al., 2001) .....	25
Figura 2.16: Reconstrução do sinal a partir do vector dos coeficientes (Misiti et al., 2001).25	
Figura 2.17: Arquitectura base de LF com wavelet e ANN (Pindoriya et al., 2010).....	27
Figura 2.18: Arquitectura base do método WNN (Pindoriya et al., 2010) .....	27
Figura 2.19: Estrutura do modelo híbrido de STLF (Amjady & Keynia, 2009) .....	28
Figura 2.20: Diagrama de carga de dias característicos (REN, 2014a).....	29
Figura 2.21: Curva de carga de uma semana do mês de Maio .....	30
Figura 2.22: Curva de carga durante um jogo do campeonato do mundo (Guirelli, 2006).30	
Figura 3.1: Excerto do ficheiro proveniente da empresa EDP Distribuição .....	36
Figura 3.2: Excerto do ficheiro com dados de temperatura.....	36
Figura 3.3: Dados relativos ao município de Chaves (PORDATA, 2015).....	37
Figura 3.4: Consumo de energia eléctrica total e por tipo de consumo (PORDATA, 2015)37	
Figura 3.5: Topologia da rede de distribuição .....	38
Figura 3.6: Excerto da Rede Nacional de Transporte. Adaptado (“REN - Eletricidade,” 2015).....	38
Figura 3.7: Excerto da tabela das temperaturas médias de cada dia do ano .....	40
Figura 3.8: Temperatura média em Chaves no ano 2012.....	41
Figura 3.9: Relação entre a temperatura e o consumo ocorrido na SE durante o ano 2012.41	
Figura 3.10: Diagrama de carga semanal.....	42
Figura 4.1: Ilustração da folha de cálculo <i>Excel</i> com a estrutura das variáveis de entrada .45	

Figura 4.2: Função Wavelet Daubechies de ordem 2 .....	46
Figura 4.3: Primeiro modelo para STLF.....	47
Figura 4.4: Exemplo de TWD com função db2 e 3 níveis de decomposição .....	47
Figura 4.5: Função Wavelet Daubechies de ordem 4 .....	48
Figura 4.6: Exemplo de uma aproximação com função wavelet db4.....	49
Figura 4.7: Segundo modelo para STLF.....	49
Figura 4.8: Ilustração do cálculo da média utilizada nos algoritmos.....	52
Figura 4.9: Arquitectura do algoritmo Sem temperatura .....	52
Figura 4.10: Arquitectura dos algoritmos que utilizam temperatura .....	53
Figura 4.11: Ilustração gráfica da Tabela 4.4 .....	56
Figura 4.12: Valor médio do MAPE de cada tipo de dia da semana.....	57
Figura 4.13: Ilustração gráfica dos valores de carga previstos e registados para o modelo 1 .....	58
Figura 4.14: Ilustração gráfica dos valores de energia previstos e registados para o modelo 1.....	58
Figura 4.15: Valor do MAPE em cada ponto durante a previsão para o modelo 1 .....	59
Figura 4.16: Histograma da diferença entre o valor previsto e o registado para o modelo 1 .....	59
Figura 4.17: Mensagem apresentada na consola do Matlab para uma simulação do modelo 1.....	60
Figura 4.18: Ilustração gráfica da Tabela 4.7 .....	61
Figura 4.19: Valor médio do MAPE de cada tipo de dia da semana.....	63
Figura 4.20: Ilustração gráfica dos valores de carga previstos e registados para o modelo 2 .....	63
Figura 4.21: Ilustração gráfica dos valores de energia previstos e registados para o modelo 2.....	64
Figura 4.22: Valor do MAPE em cada ponto durante a previsão para o modelo 2 .....	64

Figura 4.23: Histograma da diferença entre o valor previsto e o registado para o modelo 2	65
Figura 4.24: Mensagem apresentada na consola do Matlab para uma simulação do modelo 2	65
Figura 4.25: Comparação entre os valores médios diários anuais do MAE para os dois modelos de previsão	66
Figura 4.26: Comparação entre os valores médios diários anuais do MAPE para os dois modelos de previsão	67

## LISTA DE TABELAS

Tabela 2.1: Resumo dos métodos de previsão .....	34
Tabela 3.1: Dados da rede fornecidos pela empresa EDP Distribuição .....	39
Tabela 4.1: Candidatas a variáveis de entrada do sistema de previsão .....	44
Tabela 4.2: Matriz de previsão para dias não feriado .....	50
Tabela 4.3: Matriz de previsão para dias feriado.....	51
Tabela 4.4: Valores médios diários de cada mês.....	55
Tabela 4.5: Média diária anual.....	56
Tabela 4.6: Melhor dia de cada mês .....	57
Tabela 4.7: Valores médios diários de cada mês.....	61
Tabela 4.8: Média diária anual.....	62
Tabela 4.9: Melhor dia de cada mês .....	62



# ABREVIATURAS E SÍMBOLOS

## Lista de Abreviaturas

<b>ANN</b>	Redes Neurais Artificiais ( " <i>artificial neural networks</i> ")
<b>AT</b>	Alta Tensão
<b>BT</b>	Baixa Tensão
<b>CUR</b>	Comercializador de Último Recurso
<b>EDP</b>	Energias de Portugal
<b>GWh</b>	Gigawatt hora
<b>IA</b>	Inteligência Artificial
<b>kV</b>	Quilovolt
<b>kWh</b>	Quilowatt hora
<b>LF</b>	Previsão de consumo (" <i>load forecasting</i> ")
<b>MAE</b>	Erro Absoluto Médio (" <i>mean absolute error</i> ")
<b>MAPE</b>	Percentagem Absoluta Média do Erro (" <i>mean absolute percentage error</i> ")
<b>MAT</b>	Muito Alta Tensão
<b>MT</b>	Média Tensão

<b>MVA</b>	Megavoltampére
<b>MW</b>	Megawatt
<b>MWh</b>	Megawatt hora
<b>PT</b>	Posto de Transformação
<b>PTC</b>	Posto de Transformação Cliente
<b>PTD</b>	Posto de Transformação Distribuição
<b>REN</b>	Rede Energética Nacional
<b>RND</b>	Rede Nacional de Distribuição
<b>RNT</b>	Rede Nacional de Transporte
<b>SE</b>	Subestação Eléctrica
<b>SEN</b>	Sistema Eléctrico Nacional
<b>STLF</b>	Previsão de consumo de curto-prazo ( <i>“short-term load forecasting”</i> )
<b>SVM</b>	<i>Support Vector Machine</i>
<b>TF</b>	Transformada de Fourier
<b>TW</b>	Transformada de Wavelet
<b>TWC</b>	Transformada de Wavelet Contínua
<b>TWD</b>	Transformada de Wavelet Discreta
<b>TWDI</b>	Transformada Wavelet Discreta Inversa
<b>TWh</b>	Terawatt hora
<b>WNN</b>	<i>Wavelet Neural Network</i>



## Lista de Símbolos

$\psi$	Função da família Wavelet
$y_i$	Valor verificado
$\hat{y}$	Valor previsto
$ne$	Número de elementos

Nos casos em que se entender ser necessário referir o plural de algumas destas abreviaturas, acrescenta-se um “s” minúsculo. Por exemplo, SEs significa Subestações Eléctricas. Também é de referir que, de uma forma geral, os acrónimos são resultantes da contracção dos termos em Português, por exemplo, AT para Alta Tensão. Existem todavia casos em que os termos em inglês entraram na escrita em português, pelo que se utilizam os respectivos acrónimos em inglês. Um exemplo disto é o caso de STLF, para *short-term load forecasting*, sempre que se pretender fazer referência à previsão de curto-prazo.



# 1 INTRODUÇÃO

## 1.1 Motivação e Contexto


A actividade de produção de energia eléctrica, bem como o seu transporte e distribuição até aos consumidores finais iniciou-se no final do século XIX e, desde essa altura, o sector tem conhecido muitas transformações aos mais variados níveis. Na sua fase inicial, o sector eléctrico era formado por redes eléctricas de pequena potência e dimensão geográfica reduzida, não só pelo valor diminuto das potências de carga envolvidas, mas também devido às tecnologias disponíveis na altura (Saraiva, Silva, & Leão, 2002). À medida que as potências de carga foram aumentando e a tecnologia foi evoluindo, a extensão geográfica das redes e as potências envolvidas também começaram a sofrer incrementos. Com estas evoluções e, a par do aproveitamento de recursos hídricos muitas vezes situados em locais afastados dos centros de consumo, originou a construção de redes de transporte de energia cada vez maiores e com níveis de tensão mais elevados (Saraiva et al., 2002). Com o passar do tempo foram criados sistemas de energia que cobrem grandes extensões geográficas, muitas vezes, correspondentes ao território de todo um país. Mais tarde por razões de segurança e estabilidade de exploração, procedeu-se à interligação dos diferentes sistemas eléctricos nacionais (Saraiva et al., 2002).

Vive-se actualmente uma época em que a energia se tornou um vector essencial para o desenvolvimento das nações, constituindo o motor que alimenta o seu progresso (“ERSE - Plano de Promoção da Eficiência no Consumo de Energia Eléctrica,” 2015). A sociedade em geral, e em particular a população dos países desenvolvidos, tem sofrido nas últimas décadas um grande aumento da necessidade de utilização de energia eléctrica, tornando-se um bem essencial e indispensável no dia-a-dia de cada pessoa. Este au-


mento teve de ser compensado com uma garantia de fornecimento de energia e integração de índices de qualidade de energia eléctrica (Fernandes, 2012).

Vários esforços estão a ser levados a cabo com a finalidade de ajudar a abrandar o consumo abrupto de energia eléctrica em todo o mundo. Alguns dos exemplos mais conhecidos são, por exemplo, a introdução de lâmpadas LED que conseguem poupanças superiores a 80%, a diminuição de consumo por parte dos dispositivos eléctricos comuns, sistemas de domótica que permitam a gestão dos recursos numa habitação ou empresa, os isolamentos cada vez melhores dos edifícios e muitos outros procedimentos (T. M. Ferreira, 2013).

Em Portugal, no ano de 2013, segundo (REN, 2014a) o consumo de energia eléctrica totalizou 49,2 TWh. Este valor traduz o agregado da produção líquida injectada na rede pública pelos centros produtores, de origem renovável e não renovável, e o saldo de trocas internacionais, subtraído do consumo para bombagem hidroeléctrica. O consumo de energia eléctrica teve em 2013 um acréscimo de 0,2% relativamente a 2012, situando-se, mesmo assim, cerca de 5,8% abaixo do máximo histórico ocorrido em 2010, que foi de 52,2 TWh (REN, 2011). A potência máxima verificada em 2013 no Sistema Eléctrico Nacional (SEN) foi de 8322 MW, em que, este valor é cerca de 1000 MW inferior ao máximo histórico registado em 2010. Na Figura 1.1 e 1.2 apresentam-se, respectivamente, o valor máximo de ponta do consumo do SEN ocorrido durante o ano de 2013 e a evolução do consumo de energia em Portugal.



**Figura 1.1: Pontas de consumo na Rede Nacional de Transporte (RNT) e na Rede Pública em 2013 (REN, 2014a)**

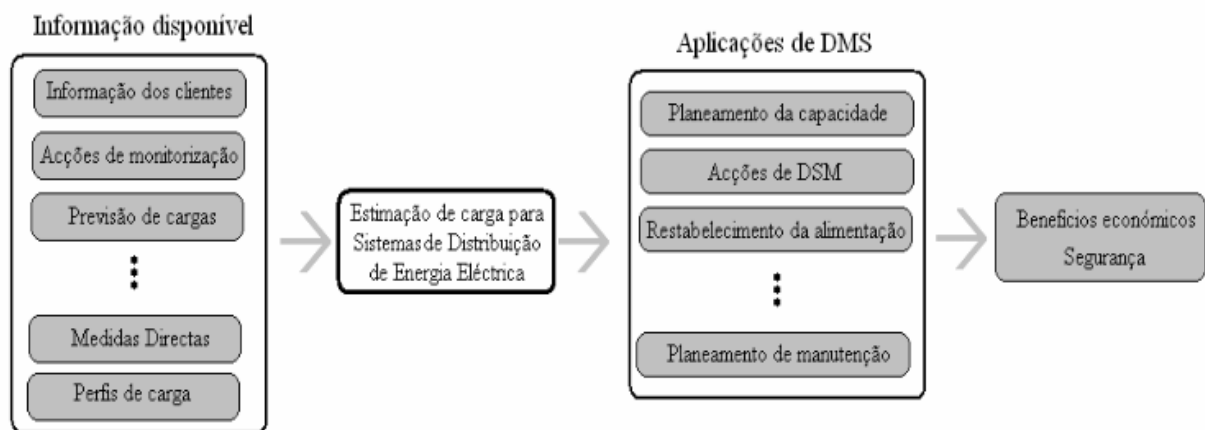


**Figura 1.2: Evolução do Consumo de Energia em Portugal (REN, 2014b)**

A previsão de consumos (LF) de energia eléctrica é uma tarefa de reconhecida importância histórica, no que concerne ao planeamento dos sistemas de energia (Fan & Hyndman, 2012). Os sistemas de previsão têm-se tornado, nos últimos anos, uma das áreas de estudo com grande incidência, a comprovar isso, basta observar o elevado número de aplicações e publicações científicas recentes (Bonanno, Capizzi, & Sciuto, 2013; Božić, Stojanović, Stajić, & Tasić, 2013; Chaturvedi, Premdayal, & Chandiok, 2013; Fard & Zadeh, 2013; Guan, 2013; Kapgate & Mohod, 2013). Este interesse tem sido fomentado pelo tipo de dinâmica que a rede de distribuição eléctrica tem vindo a tomar, resultando num problema que num passado recente não existia. Por um lado, a LF é fundamental, uma vez, que o comercializador de energia necessita de obter essa estimativa, o mais correcta possível, para a comprar nos mercados diários, sendo penalizado quer se verifique um desvio por excesso, quer por defeito, entre os valores contratados e os que são efectivamente medidos. Por outro lado, também se torna vantajoso numa óptica de médio/longo prazo para possibilitar uma análise das necessidades de reforço ou expansão das infra-estruturas existentes, bem como, no planeamento de acções de manutenção para garantir um funcionamento fiável do sistema eléctrico. Numa perspectiva de curto-prazo, a LF pode tornar-se importante para encontrar uma optimizada configuração da rede, que possibilite uma melhor decisão sobre as unidades de geração que devem satisfazer a procura e também para facilitar decisões relacionadas com a integração da geração distribuída, como é o caso dos Produtores em Regime Especial (PRE) (Sousa, 2013). Com um planeamento adequado, poderá consumir-se o objectivo de ter electricidade disponível em

qualquer instante para satisfazer a procura, ao mais baixo custo e sem colocar em risco o normal funcionamento do sistema.

Actualmente, um sistema de previsão de consumo de energia, assume-se como uma ferramenta de grande relevo, não só, na gestão da rede eléctrica, mas também na área dos mercados de energia (Figura 1.3), tal como foi enunciado no parágrafo anterior. Seguindo esta linha de pensamento, o trabalho de dissertação proposto, de desenvolvimento de uma ferramenta de previsão de consumos de energia do dia seguinte com recurso a wavelets, faz todo o sentido, visto que neste momento em Portugal não existe qualquer ferramenta deste tipo, pelo menos que seja conhecida publicamente, ao nível do sector de distribuição de electricidade concessionado pela empresa subsidiária do grupo Energias de Portugal (EDP) com o nome EDP Distribuição.



**Figura 1.3: Esquema com a importância dos sistemas de previsão no domínio dos sistemas de distribuição (Santos, 2005)**

A Rede Eléctrica Nacional (REN) possui um sistema de previsão capaz de efectuar uma previsão diária, até 11 dias á frente (Figura 1.5), ou semanal, mas no que ao consumo total da Rede Nacional de Transporte (RNT) diz respeito, como tal, não faz sentido ser utilizado pelos distribuidores de energia, uma vez, que só dá a informação total do consumo a nível nacional. Este pressuposto só vem dar ainda mais ênfase à relevância deste trabalho, na medida, em que se abre uma janela de oportunidade para suprir uma lacuna existente neste domínio. A REN também disponibiliza a informação em tempo real do consumo total da RNT, bem como a previsão para a hora seguinte (Figura 1.4).




Figura 1.4: Previsão de consumo e consumo efectivo em tempo real, a nível nacional, da REN (“REN - Eletricidade,” 2015)

**HORAS** ⓘ

HORA	11 Mar	12 Mar	13 Mar	14 Mar	15 Mar	16 Mar	17 Mar	18 Mar	19 Mar	20 Mar	21 Mar
1	5337	5369	6555	5684	5348	5123	5831	5759	5775	5712	5720
2	4851	5022	5725	5189	4867	4613	5047	5061	4997	5004	5156
3	4532	4722	5247	4743	4411	4231	4626	4639	4580	4586	4733
4	4547	4598	4968	4422	4099	4003	4380	4392	4330	4336	4433
5	4578	4538	4843	4253	3928	3917	4270	4282	4218	4224	4271
6	4546	4515	4796	4155	3851	3897	4229	4240	4177	4183	4197
7	4670	4633	4874	4138	3842	3985	4297	4308	4242	4248	4189
8	4825	4825	5143	4173	3828	4308	4534	4546	4433	4439	4140
9	5282	5282	5708	4150	3669	4839	5033	5046	4956	4963	4174
10	6086	6086	7006	4669	3949	6060	6177	6194	6108	6117	4715
11	6414	6414	7602	5220	4395	6711	6702	6720	6658	6668	5272
12	6399	6341	7736	5510	4773	6864	6821	6839	6767	6776	5536
13	6518	6343	7884	5608	5025	7014	6951	6970	6896	6906	5654
14	6388	6213	7487	5551	5098	6691	6601	6619	6570	6579	5613
15	6344	6169	7332	5323	4874	6573	6465	6482	6426	6435	5359
16	6400	6225	7662	5269	4671	6864	6756	6774	6743	6753	5318
17	6344	6169	7642	5184	4526	6832	6738	6756	6726	6735	5218
18	6242	6067	7561	5069	4409	6755	6667	6684	6649	6659	5113
19	6159	5984	7289	5069	4453	6518	6426	6444	6405	6414	5085
20	6531	6356	7336	5407	4836	6535	6468	6485	6376	6385	5344
21	7145	6970	8123	6372	5849	7237	7162	7181	7061	7071	6278
22	7059	6884	8009	6428	6020	7163	7061	7080	7008	7018	6355
23	6697	6522	7692	6123	5912	6917	6782	6800	6729	6738	6062
24	6429	6254	7252	5751	5625	6497	6394	6411	6335	6344	5662

Unidades: MW

Figura 1.5: Previsão do consumo eléctrico diário, a nível nacional, da REN (“Previsão de consumo diário,” 2015)

O processo de liberalização do mercado de energia eléctrica em Portugal, veio acrescentar uma maior importância à temática de previsão de consumos. Em Portugal a liberalização ocorreu na produção e na comercialização, isto é, qualquer uma destas actividades pode ser exercida de forma livre mediante uma licença. As actividades de transporte e de distribuição mantiveram-se reguladas. Com mais agentes económicos envolvidos, os modelos de previsão tornam-se uma ferramenta essencial para simplificar e fundamentar as trocas comerciais. É reconhecido que previsões acima ou abaixo do valor real de procura conduzem a perdas económicas e/ou custos operacionais elevados, porquanto torna-se vital a adopção de métodos apropriados que minimizem os erros de previsão.

O mercado de energia é muito assimétrico uma vez que há uma muito reduzida elasticidade da procura em relação ao preço, tal como é típico nos mercados de electricidade. Trata-se de um mercado dominado pelo lado da produção em que actuam um reduzido número de agentes que detêm informação adicional sobre a carga. A carga é muito pouco elástica, como pode ser visto na Figura 1.6, pelo que se encontra disponível para pagar o que for necessário para ser alimentada. O preço final da electricidade para cada hora do dia resulta do encontro entre a oferta e a procura. Num dia não existe um preço para o activo, mas sim 24 preços, um para cada hora do dia. Existem 24 curvas da oferta e da procura ("O negócio da electricidade em Portugal," 2015). As ordens de venda são colocadas pelas empresas produtoras, enquanto as ordens de compra são colocadas pelas distribuidoras e pelas comercializadoras. À parte das PREs, as restantes formas de produção entram na rede através da ordem de mérito, que é a ordenação crescente das diferentes tecnologias por custo marginal de produção. A tecnologia mais cara que conseguir casar a sua oferta de venda em mercado para cada hora é a que marca o preço de mercado, isto é, é o que define o preço horário a que as outras tecnologias com custo marginal de produção mais baixo vão vender a energia.






Figura 1.6: Curvas agregadas típicas da relação entre a procura/oferta nos mercados de energia eléctrica (Sousa, 2013)

O mercado ibérico de electricidade (MIEBL) funciona cada vez mais como um sistema acoplado, uma vez que o diferencial de preços entre Portugal e Espanha tem vindo a reduzir-se. Era superior a 9 €/MWh em 2007 e passou para um valor inferior a 1 €/MWh em 2011. Por outro lado, o número de horas em que o MIBEL funcionou com duas áreas de preços desacopladas foi superior a 80% em 2007 e reduziu-se para cerca de 5% em 2011. O preço médio no mercado diário foi de 52,2 €/MWh em 2007 tendo passado para 50,5 €/MWh em 2011. Este preço médio foi de 37,3 €/MWh em 2010 fruto de um ano muito favorável do ponto de vista hidrológico e foi de 70,0 €/MWh em 2008 devido à redução das afluências hídricas, estes dados são visíveis na Figura 1.7.

	2010	2011	2012	2013	2014
<b>Preço Mercado Diário [€/MWh]</b>					
Preço Médio					
<b>MIBEL PT</b>	<b>37.3</b>	<b>50.5</b>	<b>48.1</b>	<b>43.6</b>	<b>41.9</b>
MIBEL ES	37.0	49.9	47.2	44.3	42.1
França	47.5	48.9	46.9	43.2	34.6
<b>Preço Ponderado</b>					
<b>MIBEL PT</b>	<b>40.0</b>	<b>51.8</b>	<b>49.2</b>	<b>44.8</b>	<b>42.4</b>
MIBEL ES	38.0	50.8	48.5	44.3	42.0
<b>Energia Transacionada [TWh]</b>					
	265	265	280	273	258
<b>Consumo abastecido pelo Mercado PT [%]</b>					
	66%	66%	100%	100%	100%
<b>Contratos Bilaterais [GWh]</b>					
	301	0	0	0	26
<i>não inclui unidades de programação genéricas</i>					

Figura 1.7: Valores de energia no MIEBL ("Mercado REN," 2015)

## 1.2 Objectivos Propostos

Neste trabalho de dissertação, pretende-se desenvolver um sistema de previsão de consumo de energia para o dia seguinte (hora a hora) com o recurso a wavelets, capaz de apresentar o consumo associado a cada período horário ao longo do dia. Pretende-se que o sistema desenvolvido receba um determinado dia do ano para o qual se quer efectuar a previsão, e que retorne um vector com os 24 valores de consumo diário do dia em causa.

Para se conseguir atingir o objectivo proposto, o trabalho efectuado passou pelas seguintes etapas:

- Numa primeira fase, foi necessário realizar uma pesquisa bibliográfica abrangente sobre o tema em causa, em que as palavras-chave mais utilizadas foram “previsão do consumo de energia a curto prazo” e “wavelets”;
- Recolha de dados relativos ao trânsito de potência ocorridos na subestação eléctrica (SE) de transformação em causa (Concelho de Chaves);
- Tratamento dos dados recolhidos, por forma a estabelecer diagramas de carga;
- Estudo dos factores que possam influenciar o consumo de energia no local em causa (efeitos meteorológicos, hora do dia, dia de semana, entre outros);
- Construção de uma tabela de dados necessários para iniciar a implementação do sistema de previsão;
- Desenvolvimento e implementação dos vários modelos de previsão com recurso a wavelets;
- Simulações dos vários modelos desenvolvidos e respectivas comparações de resultados, aferindo sobre o seu comportamento, nomeadamente sobre o erro de previsão gerado.

### 1.3 Contributos Originais

Com o trabalho desenvolvido, podem ser destacados os seguintes contributos originais:

- Uma análise profunda sobre os padrões sazonais de consumo no concelho de Chaves, levando ao melhor entendimento das curvas de carga;
- Desenvolvimento de uma metodologia de previsão de carga e energia para a região em causa, podendo, numa fase posterior até ser extrapolada para outras zonas;
- Uma avaliação conceptual dos vários métodos de previsão, desde as séries temporais até ao uso de técnicas de Inteligência Artificial (IA);
- Avaliação do uso de transformada de wavelet como ferramenta de filtragem de dados;
- Avaliação de qual o melhor tipo de wavelets a aplicar no conceito de previsão de cargas;
- Previsão de consumo com recurso a wavelets, sem ser em conjunto com redes neurais;
- Concepção de um novo algoritmo de LF.

### 1.4 Estrutura da Dissertação

O presente documento de dissertação de mestrado encontra-se dividido em 5 capítulos e alguns anexos que se encontrou pertinente apresentar.

Após o enquadramento que se pretende transmitir no presente capítulo acerca dos conteúdos, das motivações e dos propósitos desta dissertação, os restantes capítulos estão organizados da seguinte forma:

- O capítulo 2, Revisão da Literatura, descreve o actual estado da arte, enunciando e descrevendo sumariamente os principais métodos e tipos de previsão existentes no consumo de energia, dando maior destaque aos métodos de curto prazo. Neste mesmo capítulo será abordado a temática das wavelets, uma vez que são um dos focos deste trabalho. Ainda neste capítulo será feita uma resenha sobre a organiza-

ção do SEN, bem como de alguns dos factores que possam condicionar os diagramas de carga;

- O capítulo 3, Estudo de Caso, centra-se na descrição do local em causa correspondente aos dados fornecidos. Esta descrição passa, numa primeira fase, em enquadrar o ponto injector de recolha dos dados no SEN e, posteriormente, realizar uma inferência de forma a decifrar quais os possíveis factores que influenciam o consumo de potência activa nesse mesmo ponto injector;
- O capítulo 4, Modelos de Previsão Propostos, tem como principal objectivo revelar, avaliar e comparar os modelos de previsão desenvolvidos. Neste capítulo é apresentado toda a estrutura do vector das variáveis de entrada do sistema, bem como, todo o pré-processamento dos dados fornecidos. Também é feita uma referência ao tipo de ambientes computacionais utilizados para a realização deste trabalho;
- O capítulo 5, Conclusões e Trabalhos Futuros, apresenta as principais conclusões provenientes do trabalho realizado, bem como, são identificadas algumas possibilidades de trabalhos futuros no mesmo domínio de acção.

No que aos anexos diz respeito, são apresentados 6, sendo um referente aos tipos de funções da família das wavelets e os outros 5 são excertos de código de programação Matlab.

## 2 REVISÃO DA LITERATURA

### 2.1 Sistema Eléctrico Nacional

Nos últimos 30 anos, o sector eléctrico nacional sofreu uma evolução assinalável do ponto de vista estrutural, regulamentar e ao nível das propriedades dos activos envolvidos. Até 1975, o sector eléctrico estava organizado em diversas empresas concessionárias que, neste ano, foram nacionalizadas num processo de que veio a emergir a EDP (Saraiva et al., 2002). Este panorama começou a alterar-se com a publicação do Dec. Lei 189/88 de 27 de Maio definindo um regime tarifário específico (tarifas de tipo *feed-in*) para a PRE, integrando os aproveitamentos hídricos até 10 MVA de potência instalada, a produção de energia eléctrica através de outras fontes, bem como, unidades de cogeração e produção a partir de resíduos, tendo sido alargado posteriormente à microprodução e à produção em Baixa Tensão (BT). Este regime foi sucessivamente ajustado sendo actualmente a PRE paga por tarifas baseadas em custos evitados de potência, de energia e ambientais que dependem da tecnologia e do diagrama horário de produção e que, por outro lado, pretendem garantir uma determinada rentabilidade aos investimentos realizados (Saraiva, 2015).

Em Junho de 1997 iniciou-se a privatização da EDP e em Novembro de 2000 ocorreu a autonomização jurídica das actividades de transporte e de gestão global do sistema com a criação da REN SA. A criação da Entidade Reguladora do Sector Eléctrico, posteriormente designada por Entidade Reguladora dos Serviços Energéticos (ERSE) foi igualmente consagrada em 1995. A partir de 1998, a ERSE publicou um conjunto de regulamentos, nomeadamente o Regulamento Tarifário, que passaram a enquadrar o funcionamento do sector nos anos seguintes. Um outro marco importante nesta fase correspondeu à publicação do Regulamento de Qualidade de Serviço. A sua primeira versão, publicada em Junho

de 2000, era ainda pouco exigente tendo sido actualizada em Fevereiro de 2003 e, finalmente, em Março de 2006 (Saraiva, 2015).

Em Novembro de 2001 foi assinado um memorando entre os governos de Portugal e de Espanha tendo em vista lançar as bases para o estabelecimento de um mercado comum de electricidade, MIBEL. Assim, o funcionamento do mercado a prazo iniciou-se em 2004 e o mercado comum diário em 1 de Julho de 2007, este como extensão a agentes nacionais do mercado diário já existente em Espanha. A este nível, é ainda de assinalar o aumento progressivo da capacidade de interligação, de tal forma, que as situações de congestionamento nas interligações têm vindo a diminuir desde 2007 até hoje, permitindo igualmente uma aproximação muito substancial dos preços no mercado grossista nos dois países.

Para suportar do ponto de vista legal a actuação de agentes nacionais no MIBEL foi revogada a legislação publicada em 1995 e foi publicado o Dec. Lei 29/2006 de 15 de Fevereiro. Este decreto organizou o SEN em quatro actividades fundamentais (Figura 2.1) – produção (em regime ordinário e especial), transporte, distribuição e comercialização. Este Dec. Lei transpôs as normas da Directiva EU/2003/54 de 26 de Junho e, de acordo com ele, as actividades de produção em regime ordinário e de comercialização são exercidas em regime de mercado e as actividades de rede (transporte e distribuição) são reguladas e exercidas ao abrigo de concessões da RNT, da Rede Nacional de Distribuição (RND) e das redes de BT, sendo estas últimas concessões atribuídas pelos municípios (Saraiva, 2015).

Produção	Transporte	Distribuição	Comercialização
<b>Regime Ordinário</b> <ul style="list-style-type: none"> <li>• EDP Produção (CAE a terminar)</li> <li>• EDP Produção (Central TER e várias Centrais hidroeléctricas)</li> <li>• EDIA</li> <li>• Outros produtores</li> <li>• Turbogás (através de CAE)</li> <li>• Tejo Energia (através de CAE)</li> </ul> <b>Regime especial</b> <ul style="list-style-type: none"> <li>• Produtores de fontes renováveis e de biomassa</li> <li>• Co-geração</li> </ul>	<b>Rede Nacional de Transporte</b> <ul style="list-style-type: none"> <li>• Muito Alta Tensão (Concessão de Serviço Público)</li> <li>• REN - Redes Energéticas Nacionais</li> </ul>	<b>Rede Nacional de Distribuição</b> <ul style="list-style-type: none"> <li>• Alta e Média Tensão (Concessão de serviço público)</li> <li>• EDP - Distribuição Baixa Tensão</li> <li>• Distribuidores (Concessões municipais)</li> <li>• EDP - Distribuição</li> <li>• Vários cooperativos</li> </ul>	<b>Comercializadores regulados (Comercializador de último recurso)</b> <ul style="list-style-type: none"> <li>• EDP Serviço Universal</li> <li>• Cooperativas de consumidores</li> </ul> <b>Comercializadores não regulados</b> <ul style="list-style-type: none"> <li>• EDP Comercial</li> <li>• Endesa / Sodesa</li> <li>• Iberdrola</li> <li>• União Fenosa</li> <li>• Viesgo</li> <li>• Outros</li> </ul>

Figura 2.1: Actividades fundamentais do SEN (Mourão, 2012)

Segundo a EDP (“EDP - Sistema Eléctrico Português,” 2015) e de acordo com a Lei Base da Electricidade, o SEN divide-se em seis grandes áreas: produção, transporte, distribuição, comercialização, operação do mercado eléctrico e operações logísticas facilitadoras da transferência entre comercializadores pelos consumidores. Salvo algumas excepções, cada uma destas áreas é operada independentemente, quer do ponto de vista legal, organizacional ou decisório. Estas actividades são desenvolvidas de acordo com princípios de racionalidade e eficiência na utilização de recursos ao longo de toda a cadeia de valor, promovendo a eficiência no SEN.

Nas secções seguintes serão abordadas cada uma das seis áreas individualmente, de uma forma resumida.

### 2.1.1 Produção de Electricidade

A produção de electricidade está sujeita a licenciamento e é desenvolvida num contexto de concorrência. A produção de electricidade está aberta à concorrência e tem dois regimes legais: (i) produção em regime ordinário (PRO), relativa à produção de electricidade com base em fontes tradicionais não renováveis e em grandes centros electroprodutores hídricos, e (ii) PRE relativa à cogeração e à produção eléctrica a partir da utilização de fontes de energia renováveis.

De acordo com (REN, 2014a), no final de 2013, o valor total da potência de produção instalada era de 17792 MW, dos quais 10913 MW são de origem renovável e 6879 MW de origem não renovável. A potência total correspondente às centrais de PRO registou 10989 MW, enquanto a PRE registou 6803 MW. A produção de origem renovável abasteceu 58% do consumo, repartida da seguinte forma visível na Figura 2.2.




Figura 2.2: Energia produzida por tipo de central (REN, 2014a)

Relativamente à PRE, com um total de 22,1 TWh, apresentou uma distribuição repartida da seguinte forma: eólica com 11,8 TWh. Hídrica com 1,3 TWh, térmica com 8,6 TWh e solar com 0,4 TWh. Na Figura 2.3, ilustra-se a distribuição percentual da emissão de PRE em 2013.




Figura 2.3: Emissão de PRE relativa a 2013 (REN, 2014a)

## 2.1.2 Transporte de Electricidade

A actividade de transporte de electricidade é desenvolvida através da RNT, ao abrigo de uma concessão exclusiva atribuída pelo Estado Português. Actualmente, a concessão exclusiva da transmissão de electricidade está concedida à REN.

A RNT cobre todo o território de Portugal Continental e em 2013 tinha ao serviço 67 subestações, 10 postos de corte, 2 de seccionamento, 1 de transição e um conjunto de linhas com as características apresentadas na Figura 2.4.

	31-12-2013	31-12-2012
<b>Comprimento de linhas em serviço (km)</b>	<b>8 733</b>	<b>8 534</b>
400 kV	2 434	2 333
220 kV	3 565	3 521
150 kV *	2 734	2 680
<b>Potência de transformação em serviço (MVA)</b>	<b>34 984</b>	<b>33 915</b>
Autotransformação (MAT/MAT)	13 410	13 410
Transformação (MAT/AT)	21 254	20 505
Transformação (MAT/MT)**	320	-

Figura 2.4: Síntese dos principais equipamentos da RNT (REN, 2014a)



Os pontos injectores definem, de certa forma, uma fronteira no SEN entre a RNT e a RND. Esta fronteira é verificada sob a forma de subestações de Muito Alta Tensão/Alta Tensão (MAT/AT). Esta transformação de nível de tensão representa uma passagem de concessão da REN para a EDP, esta situação está ilustrada na Figura 2.5.

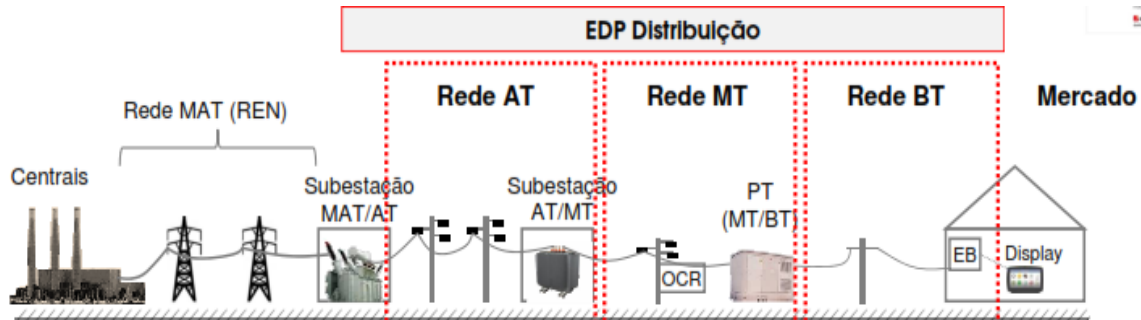


Figura 2.5: Esquema geral do SEN (EDP, 2011a)

### 2.1.3 Distribuição de Electricidade

A distribuição de electricidade no âmbito da Nova Lei Base de Electricidade tem por base a RND, que consiste na rede de média e alta tensão e ainda as redes de distribuição de baixa tensão. A rede nacional de distribuição é operada através de uma concessão exclusiva atribuída pelo Estado Português. Esta concessão exclusiva do direito de operar a rede nacional de distribuição está atribuída à subsidiária do grupo EDP, EDP Distribuição. As redes de distribuição de baixa tensão continuam a ser operadas ao abrigo de acordos de concessão firmados mediante concurso público lançado pelos municípios ("EDP - Sistema Eléctrico Português," 2015).

A rede de AT tem um nível de tensão de 60 kV, enquanto a rede de MT possui níveis de tensão de 30 kV, 15 kV, 10 kV e 6 kV. No caso da BT o nível de tensão corresponde a 400/230 V. A função da RND é estabelecer a ligação entre a rede de transporte e as instalações consumidoras, ou seja, a energia após ser produzida e ser transportada na RNT entra na RND, onde é reduzido o nível de tensão através das SE para ser conduzida até às instalações consumidoras (Coelho, 2012). Na Figura 2.6 pode ser visto o exemplo do fluxo de energia na RND. No final do ano de 2013 a RND tinha as instalações e equipamentos apresentados na Figura 2.7.

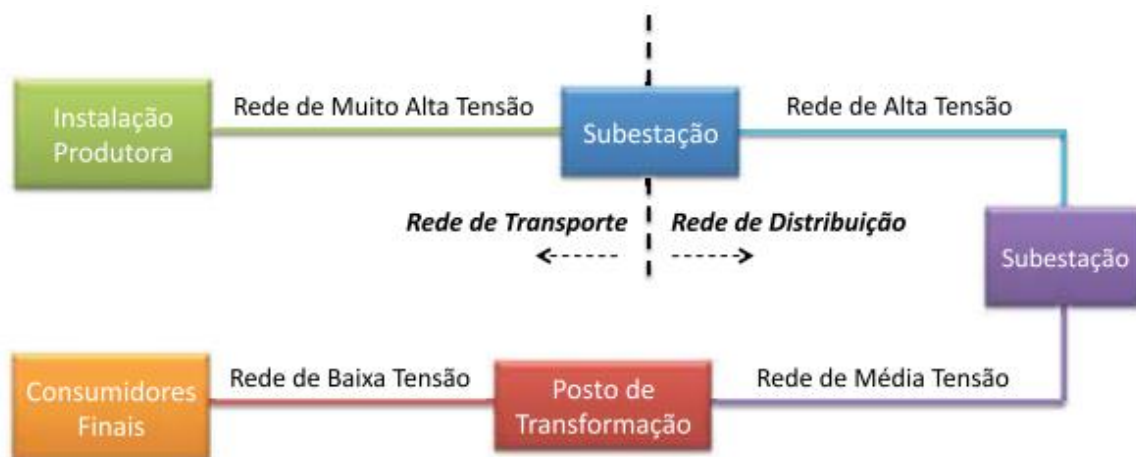


Figura 2.6: Fluxo energético desde o produtor até ao consumidor (EDP, 2011b)

	2013
<b>Subestações</b>	
N.º de Subestações	411
N.º de Transformadores	719
Potência Instalada (MVA)	17.093
<b>Linhas (incluindo ramais, em km)</b>	<b>83.542</b>
<b>Aéreas</b>	<b>66.974</b>
AT (60/130/150 kV)	8.779
MT (<6/10/15/30/40 kV)	58.195
<b>Cabos Subterrâneos</b>	<b>16.568</b>
AT (60/130/150 kV)	524
MT (<6/10/15/30/40 kV)	16.044

Figura 2.7: Características da RND (EDP, 2013)

### 2.1.4 Comercialização de Electricidade

Esta actividade em Portugal é exercida em regime de livre concorrência, como tal, o comercializador é livre de comprar e vender electricidade, tendo o direito de acesso às redes de transporte e distribuição, mediante o pagamento de tarifas fixadas pela Entidade Reguladora dos Serviços Energéticos (ERSE). Os consumidores podem, nas condições de mercado, escolher livremente o seu comercializador sem qualquer custo adicional. Actualmente existem ainda dois tipos de comercializador, o comercializador de último recurso (CUR) a operar no mercado regulado, e o comercializador livre a operar no mercado liberalizado. O CUR tem de gerir as diferentes formas de contractos com vista a adquirir a energia ao menor custo. Todos os desnecessários excessos de energia adquiridos pelo co-

comercializador de último recurso são revendidos no mercado organizado (“EDP - Sistema Eléctrico Português,” 2015). O CUR deve, ainda, adquirir obrigatoriamente toda a electricidade produzida pela PRE e pode também adquirir electricidade em mercados, como o MIBEL para abastecer o seus clientes. O papel de CUR é desempenhado por uma empresa do grupo EDP chamada EDP Serviço Universal, enquanto o papel de comercializador livre está a cargo de diversas empresas como a EDP Comercial, Iberdrola, Endesa, entre outras.

### **2.1.5 Operação dos Mercados de Electricidade**

A operação do mercado de electricidade organizado está sujeita a uma autorização conjunta do Ministro das Finanças e do Ministro responsável pelo sector de energia. A entidade gestora dos mercados organizados está igualmente sujeita a autorização do Ministro responsável pelo sector de energia e, quando requerido por lei, pelo Ministro das Finanças (“EDP - Sistema Eléctrico Português,” 2015).

O mercado organizado corresponde a um sistema com diferentes métodos de contratação que proporcionam o encontro de oferta e procura, compreendendo os mercados a prazo, diário (inclui a maior de transacções de energia com entrega no dia seguinte à data do contrato e com liquidação física obrigatória) e intra-diário (transacções com liquidação física obrigatória) (“EDP - Sistema Eléctrico Português,” 2015).

O mercado regulado em Portugal assenta no princípio de que as diferentes actividades do sector estão incorporadas na tarifa: a produção de electricidade, o transporte em muito alta tensão, a distribuição em alta, média e baixa tensões e a comercialização.

De acordo com (“O negócio da electricidade em Portugal,” 2015) existem várias formas dos comercializadores adquirirem energia eléctrica:

- Através do mercado *spot*;
- Através de contratação a prazo;
- Através de contractos bilaterais.

### **2.1.6 Logística na Mudança de Comercializador**

No que ao mercado diz respeito, os consumidores são livres de escolher o seu fornecedor/comercializador de electricidade, estando isentos de qualquer custo quando mudem de fornecedor. No sentido de gerir o processo de mudança de comercializador, o

qual implicará a gestão de leitura de electricidade e de contador, será criada uma entidade denominada por Operador Logístico de Mudança de Comercializador (OLMC). Esta entidade deverá ser independente das restantes entidades do SEN, tanto do ponto de vista legal, organizacional como decisório.

A transmissão, distribuição e comercialização de último recurso, bem como a logística e os termos aplicáveis às operações de mudança de comercializador e a gestão dos mercados organizados estão sujeitas à regulação da ERSE. A legislação aplicável a esta actividade não foi ainda desenvolvida. Contudo, até à criação da OLMC, a ERSE determinou que a gestão da logística para mudar de comercializador deverá ser conduzida pelo operador da rede de distribuição de média e alta tensão, actualmente a EDP Distribuição ("EDP - Sistema Eléctrico Português," 2015).

## **2.2 Wavelets**

A temática das wavelets, muito desenvolvida nos últimos 20 anos, é formada por uma união entre diversas áreas como a matemática, física, ciência da computação e engenharia. Ingrid Daubechies em (Daubechies, 1996) apresenta a história das wavelets como uma árvore com raízes profundas, orientadas em várias direcções. Neste contexto, o tronco corresponderia ao rápido desenvolvimento das wavelets na segunda metade da década de 80 através dos vários esforços de pesquisadores nos mais variados campos. A copa da árvore, composta pelos vários ramos, corresponderia às diferentes direcções e aplicações na qual as wavelets são aplicadas.

A ideia fundamental ligada às wavelets é a análise de dados de acordo com escalas variáveis no domínio do tempo e da frequência. Alguns investigadores que desenvolvem o seu trabalho nesta área, defendem que com a utilização de wavelets se está a adoptar uma nova perspectiva no domínio do processamento de dados.

### **2.2.1 Percurso Histórico**

De um ponto de vista histórico, a análise de sinais através de wavelets é um método recente, contudo os seus fundamentos matemáticos remontam ao século XIX no trabalho de Joseph Fourier, quando este lançou as bases com a sua teoria de análise de sinais no domínio da frequência. O primeiro registo da utilização do termo wavelets, remonta ao ano de 1909 num apêndice da tese de Alfred Haar, sendo desenvolvido mais á frente na década de 1970 por Jean Morlet. Nesta época, Morlet trabalhava para a companhia petrolí-

fera *Elf Aquitaine* e, a sua motivação no estudo de wavelets visava encontrar uma maneira de melhorar o tratamento de sinais geofísicos (Debnath & Shah, 2014; Thuillard, 2001).

Em 1988, Stephane Mallat proporcionou às wavelets um grande impulso através do seu trabalho em processamento digital de sinais (S Mallat, 1989), onde desenvolveu um algoritmo para calcular a transformada de wavelet de forma computacionalmente eficiente. Ele descobriu algumas relações entre filtros de quadratura, algoritmos piramidais e bases wavelet ortonormais (Stephane Mallat, 2008; Szeliski, 2009). Inspirado, em parte por estes resultados, Y. Meyer construiu a primeira wavelet não-trivial. Ao contrário das wavelets de Harr, estas são continuamente diferenciáveis, todavia não possuem suportes compactos.

Poucos anos mais tarde, Ingrid Daubechies (Daubechies, 1990) usou o trabalho de Mallat para a construção de um conjunto de funções wavelet de base ortonormais, tornando-se a pedra angular das aplicações wavelets actuais.

Desde o impulso dado por Mallat, a investigação sobre wavelets tornou-se internacional, com especial incidência nos Estados Unidos, onde é liderada pelo trabalho dos investigadores, como Ingrid Daubechies, Ronald Coifman, Victor Wickerhauser, Yves Meyer, Alex Grossmann e George Zweig.

### **2.2.2 Transformada de Wavelet**

Define-se wavelet como um pulso de duração limitada e valor médio igual a zero. O comportamento de uma wavelet é comparável ao de uma sinusóide, embora esta apresente um comportamento previsível, podendo a wavelet ser irregular e assimétrica.

As wavelet são utilizadas para lidar com o problema da não-estacionaridade, isto deve-se ao facto de fornecerem uma boa representação de sinais, tanto no domínio do tempo, como da frequência (S Mallat, 1989). Ao contrário de Fourier, as wavelet podem ser mantidas num intervalo fechado arbitrariamente pequeno, o que as torna uma ferramenta muito poderosa para analisar fenómenos transitórios rápidos. Pode ser vista uma ilustração desta diferença entre a Transformada de Wavelet (TW) e Fourier (TF) nas Figuras 2.8 e 2.9. A wavelet centra-se em pequenos intervalos de tempo, para componentes de alta frequência, e em longos intervalos para componentes de baixa frequência.

A análise multiresolução através de wavelets pode ser utilizada para fornecer as características de carga, bastante importante na previsão de consumos de energia (Reis & Silva, 2004, 2005).

São estas as principais razões que tornam esta metodologia como uma das preferidas entre os investigadores, pois este tipo de funções são mais apropriadas do que sinusóides para realizar análise de sinais.

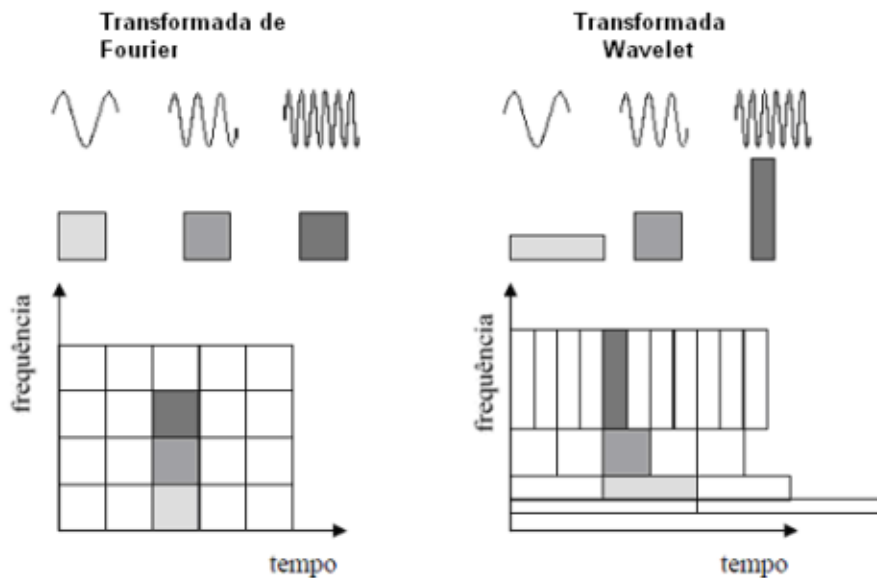


Figura 2.8: Comparação gráfica das transformadas (G. S. Andrade, 2009)

<u>Fourier Transform</u>	<u>Wavelet Transform</u>
Stationary signal Analysis	Nonstationary Transient signal Analysis
Frequency Information only, Time/space information is lost	Joint Time and Frequency Information
Single Basis Function	Many Basis Functions
Computational Cost High	Low computational costs
Analysis Structures: - FS( periodic functions only) - FT and DFT	Numerous Analysis structures: ■ CWT, ■ DWT(2 Band and M Band), ■ WP ■ DDWT, SWT, ■ Adaptive Signal Transform, Numerous Best basis selection algorithms ■ Frame structure

Figura 2.9: Comparação entre Transformada de Wavelet e Fourier (Nava, 2006)

Na aplicação da transformada de wavelet (TW) utiliza-se sempre uma função protótipo designada “wavelet mãe” (do inglês “*mother wavelet*”), que se traduz matematicamente por

$$\psi_{a,b}(x) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{x-b}{a}\right), \quad a, b \in \mathbb{R}, a \neq 0, \quad (2.1)$$

onde a variável  $x$  pode corresponder a tempo ou espaço, geradas a partir das operações de dilatação (factor de escala  $a$ ) e translação (factor  $b$ ) da mesma função  $\psi$  (wavelet mãe).

Existe um grande número de funções que podem ser utilizadas como funções wavelet, cuja lista pode ser vista na Figura 2.10 e a sua representação gráfica pode ser consultada no Anexo 1.

Wavelet Family Short Name	Wavelet Family Name
'haar'	Haar wavelet
'db'	Daubechies wavelets
'sym'	Symlets
'coif'	Coiflets
'bior'	Biorthogonal wavelets
'rbio'	Reverse biorthogonal wavelets
'meyr'	Meyer wavelet
'dmey'	Discrete approximation of Meyer wavelet
'gaus'	Gaussian wavelets
'mexh'	Mexican hat wavelet
'morl'	Morlet wavelet
'cgau'	Complex Gaussian wavelets
'shan'	Shannon wavelets
'fbsp'	Frequency B-Spline wavelets
'cmor'	Complex Morlet wavelets

**Figura 2.10: Diferentes tipos de wavelets** (Misiti, Poggi, Misiti, & Oppenheim, 2013)

A TW pode ser encontrada em duas formas:

- Transformada Wavelet Contínua (TWC): é definida como a soma de todos os instantes de um sinal, multiplicados pela função  $\psi$


- Transformada Wavelet Discreta (TWD): é definida como a discretização de um sinal em várias componentes de resolução diferentes

- Transformada Wavelet Contínua:

A TWC de um sinal  $f(x)$ , considerando a “wavelet mãe”  $\psi(x)$ , é definido por:

$$TWC(a,b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} f(x) \psi\left(\frac{x-b}{a}\right) \cdot dx, \quad a, b \in \mathbb{R}, a \neq 0, \quad (2.2)$$

onde  $a$  é o factor de escala e  $b$  o factor de translação. Um coeficiente  $TWC(a,b)$ , numa determinada escala e factor de translação, representa o quanto bem o sinal original  $f(x)$  e a função wavelet dilatada/transladada se assemelham. Assim, o conjunto de todos os coeficientes  $TWC(a,b)$  associados com um dado sinal, corresponde à representação wavelet do sinal original  $f(x)$  em relação à função wavelet  $\psi(x)$  (Reis & Silva, 2004). Isto pode ser visto na Figura 2.11 a seguir apresentada.



**Figura 2.11: Representação de um sinal em diferentes escalas e posições** (Misiti, Poggi, Misiti, & Oppenheim, 2001)

- Transformada Wavelet Discreta:

Com a TWC, através da dilatação e translação da função wavelet, gera-se uma grande quantidade de informação redundante. Para combater este facto, a função wavelet pode ser dilatada e transladada usando escalas e posições especiais baseadas em potências de 2 (Misiti et al., 2001; Reis & Silva, 2004, 2005).

A TWD usa o conceito de coeficiente de aproximação (cA) e coeficiente de detalhe (cD) como se apresenta na Figura 2.12. As aproximações são de grande escala e relacionadas com os componentes de baixa frequência, enquanto os detalhes são de pequena escala e relacionados com as componentes de alta frequência (G. S. Andrade, 2009).



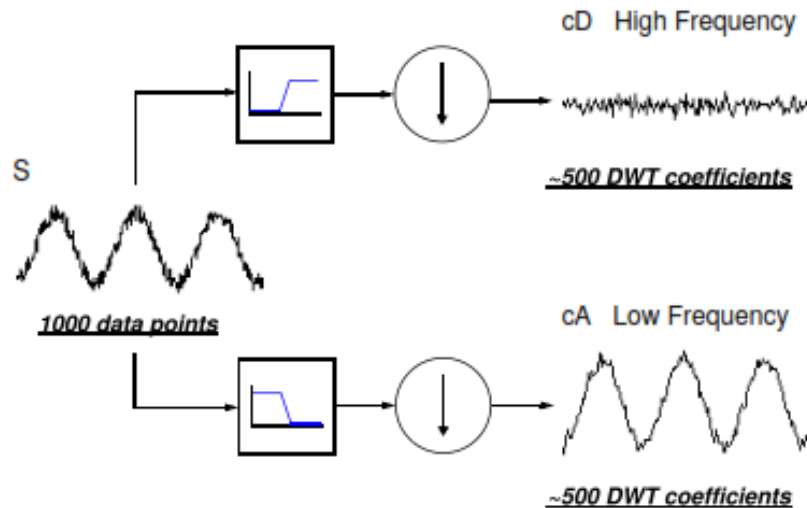


Figura 2.12: Decomposição de wavelet discreta (Misiti et al., 2001)

No primeiro passo do algoritmo, o sinal original passa em dois filtros complementares, ou seja, um filtro passa-baixo e outro filtro passa-alto. De seguida, o algoritmo extrai metade das amostras do sinal filtrado, donde resultam os coeficientes de aproximação e detalhe do sinal (Figura 2.12). Este processo de decomposição pode ser realizado em diversos níveis, resultando em vários coeficientes de detalhe e aproximação. Este processo é designado por árvore de decomposição wavelet e apresenta a forma representada na Figura 2.13. A escolha de qual o tipo de coeficiente que vai ser decomposto, bem como do número de níveis, depende do utilizador da aplicação. Porém, o processo só poderá continuar até restar apenas uma amostra.




Figura 2.13: Esquema da árvore de decomposição wavelet (Misiti et al., 2001)


A nível matemático a TWD pode ser escrita da seguinte forma:

$$(\text{TWD})(m, k) = \frac{1}{\sqrt{a_0^m}} \sum_n f(n) \psi\left(\frac{k - nb_0 a_0^m}{a_0^m}\right), \quad (2.3)$$

onde  $\psi$  é a função wavelet e os parâmetros  $a$  e  $b$  (como mostrados em (2.2)) são funções do parâmetro inteiro  $m$ , em que  $a = a_0^m$  e  $b = nb_0 a_0^m$ . Ainda em (2.3),  $k$  é uma variável inteira que se refere a uma dada amostra do sinal de entrada.

Outro aspecto importante realçar é saber como os detalhes e aproximações resultantes da DWT, podem ser reagrupados para voltar a obter o sinal original. Este processo é designado por Transformada Wavelet Discreta Inversa (TWDI) (J. C. Ferreira, 2009; Misiti et al., 2001).

Uma vez que a análise de wavelet envolve filtragem e diminuição do número de amostras, o processo inverso, consiste em aumentar novamente o número de amostras. Este número de amostras é aumentado pela introdução de zeros entre as amostras existentes (Figura 2.14).



**Figura 2.14: Processo de aumentar o número de amostras** (Misiti et al., 2001)

A parte de filtragem existente na reconstrução do sinal, também é bastante importante, em virtude da escolha do filtro ser crucial para uma perfeita operação. Com o processo de diminuição do número de amostras do sinal, pode dar origem a distorções de *aliasing*. Estas distorções podem ser canceladas com a escolha correcta do filtro a utilizar na reconstrução. Em (Strang & Nguyen, 1996) é apresentada um sistema para resolver este problema, que foi denominado por filtros de quadratura (“*quadrature mirror filters*”) com o aspecto apresentado na Figura 2.15.




Figura 2.15: Processo de decomposição e reconstrução do sinal (Misiti et al., 2001)

Também é possível reconstruir o sinal original através da soma dos vectores dos coeficientes de detalhe e aproximação, da forma apresentada na Figura 2.16.

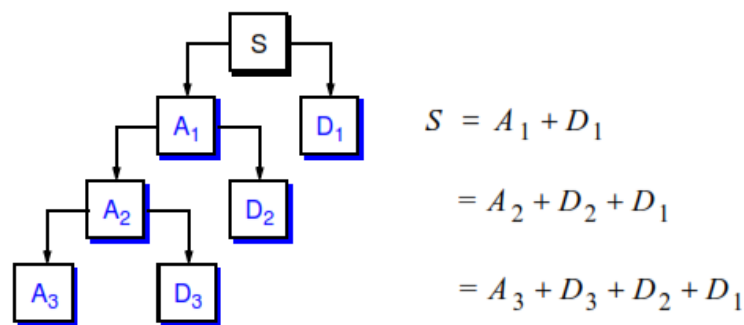


Figura 2.16: Reconstrução do sinal a partir do vector dos coeficientes (Misiti et al., 2001)

### 2.2.3 Wavelets na previsão de consumo de energia a curto prazo

As wavelets podem ser utilizadas nas mais variadas funções, que podem ser aplicadas em muitos contextos práticos da vida real, segundo (Misiti et al., 2001) as mais relevantes são:

- Detectar descontinuidades e transições bruscas num sinal;
- Detectar o padrão de evolução de sinais;
- Detectar singularidades num sinal;
- Identificar as principais frequências presentes num sinal;
- Compressão e descompressão de sinais;

- Compressão e descompressão de imagens;
- Filtragem de sinais;
- Filtragem de imagens;
- Facilitar a multiplicação de matrizes com dimensão elevada.

Como já foi dito anteriormente, os sistemas de previsão têm-se tornado, nos últimos anos, uma das áreas de estudo com grande incidência dando origem à publicação de inúmeros artigos importantes. No que á utilização de wavelets neste contexto diz respeito, também existem trabalhos importantes desenvolvidos, sendo que na sua grande maioria apresentam datas bastante recentes. Muitos modelos de previsão são propostos, mas nesta pequena revisão bibliográfica só serão abordados aqueles em que se utilizam wavelets em sistemas de previsão de curto prazo (STLF), por ser o contexto em que este trabalho está inserido. O fio condutor que liga todos os trabalhos sobre wavelets no contexto de STLF, resume-se ao propósito de que as wavelets são sempre utilizadas ao nível da filtragem ou decomposição de dados, para que depois estes sejam utilizados nos variados algoritmos de previsão.

Segundo (Guirelli, 2006) a utilização da transformada de wavelet para filtragem de dados na LF foi apresentada por (Swee & Elangovan, 1999), identificando este tipo de abordagem como um processo de grande potencial futuro.

Quase a totalidade dos sistemas de STLF que recorre ao uso de wavelets, são sistemas de IA assentes em Redes Neurais Artificiais (ANN). Alguns exemplos de trabalhos que sustentam este facto são: (Amjady & Keynia, 2009; Baniamerian, Asadi, & Yavari, 2009; Chen, Luh, & Rourke, 2010; Guan, 2013; Guan et al., 2009; Pindoriya, Singh, & Singh, 2010; Reis & Silva, 2004, 2005; Zhao, Luh, Bomgardner, & Beerel, 2009).

Em (Kapgate & Mohod, 2013; Reis & Silva, 2004, 2005) utiliza-se a TWD na STLF via redes neuronais, com o intuito de fazer uma decomposição da série de carga em diferentes componentes, tornando mais eficaz o processo de treino e validação da ANN. Também em (Chen et al., 2010; Guan et al., 2009; Zhao et al., 2009) se efectua um processo semelhante de decomposição com o mesmo propósito, em que num caso pretende-se prever o consumo na hora seguinte e noutro o consumo do dia seguinte. O princípio de funcionamento de todos estes modelos de STLF está ilustrado na Figura 2.17. Muitas das vezes o que varia de uns modelos para outros é o tipo de algoritmo de treino e validação das ANN.




Figura 2.17: Arquitectura base de LF com wavelet e ANN (Pindoriya et al., 2010)

Em (Baniamerian et al., 2009) é abordado um método diferente de STLF com recurso a wavelets utilizando ANN, denominado por *Wavelet Neural Network* (WNN). Neste método a decomposição através de wavelet é introduzida dentro da estrutura da ANN, sendo responsável pelo funcionamento de uma determinada camada, através da função de activação dos neurónios (Figura 2.18). Neste caso em concreto, foi utilizada como função de activação a função wavelet Mexican-hat. Também em (Pindoriya et al., 2010) é utilizado o mesmo método, mas com uma designação diferente de *Adaptative Wavelet Neural Network* (AWNN). Já em (Benaouda, Murtagh, Starck, & Renaud, 2006) é utilizada a função wavelet do tipo Haar.

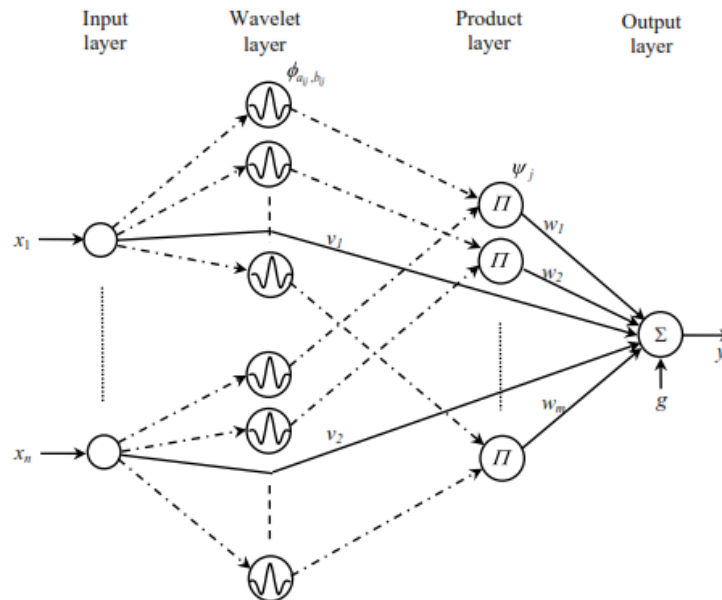


Figura 2.18: Arquitectura base do método WNN (Pindoriya et al., 2010)

Um novo modelo híbrido de STLF que integra ao mesmo tempo wavelets, ANN e um *Evolutionary Algorithm* (EA) é proposto em (Amjady & Keynia, 2009). Este modelo utiliza a função wavelet do tipo Daubechies de ordem 4 (Db4) para realizar a TWD e obter os respectivos coeficientes de detalhe, que posteriormente serão utilizados para fazer a previsão conjuntamente com a ANN e o EA). A estrutura deste modelo híbrido apresenta-se na Figura 2.19.

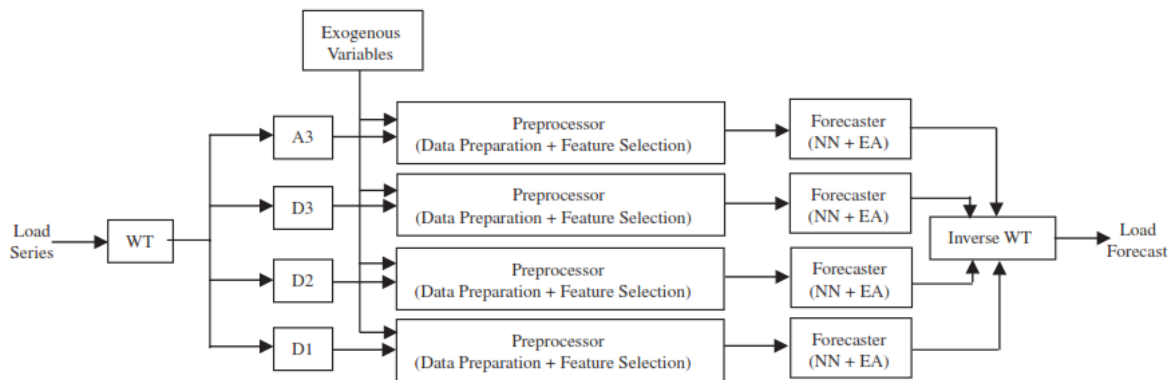


Figura 2.19: Estrutura do modelo híbrido de STLF (Amjady & Keynia, 2009)

### 2.3 Factores que influenciam a curva de carga

O diagrama de carga fornece aos gestores da rede e de todas as estruturas que nela inferem, ter um conhecimento da evolução dos consumos ao longo de uma determinada base temporal. A análise deste tipo de diagramas permite obter informações relativas aos tipos de consumidores, à sua sazonalidade e frequência.

A Figura 2.20 contém quatro diagramas de carga representativos do consumo, referentes ao dia de ponta anual (de Inverno) e a três outros das épocas sazonais de Primavera, Verão e Outono. Como qualquer outro diagrama de carga típico, este pode ser dividido em 3 fases distintas: vazio, cheia, ponta. As horas de vazio são, fundamentalmente, as horas durante o período nocturno em que a grande maioria da população está a descansar. Tipicamente, o período de cheia começa por volta das 8h da manhã, associando-se ao início das rotinas diárias de trabalho, em que os sectores como a indústria, comércio e transportes são os que mais contribuem para o crescendo da carga verificado. Durante o horário de almoço (11h-14h) é acrescentado ao consumo anterior, o consumo doméstico e o do sector da restauração. No que ao período de ponta diz respeito, é geralmente associado ao período nocturno (19h-22h), em que o valor de carga é afectado pelo consumo doméstico.

Também se pode verificar na mesma Figura 2.20 que a curva que apresenta valores mais elevados, corresponde ao dia de Inverno, logo seguida pela curva correspondente ao dia de Verão. Logo depreende-se que o efeito climatérico, nomeadamente a temperatura, é determinante no consumo de energia. Há vários trabalhos de STLF que comprovam este facto, como por exemplo, (S. Kelo & Dudul, 2012; S. M. Kelo & Dudul, 2010; Santos, 2005; Sousa, 2013)




Figura 2.20: Diagrama de carga de dias característicos (REN, 2014a)

Em relação ao impacto do dia da semana e de feriados no consumo, pode ser visto na Figura 2.21 que os dias de fim-de-semana e de feriado apresentam consumos inferiores ao dos restantes dias da semana. Existem alguns trabalhos, em que o seu principal objectivo é fazer uma previsão em dias especiais (Sá, 2013; Zhao et al., 2009).

Alguns eventos específicos, como jogos de futebol, concertos de música, episódios finais de telenovelas, possuem efeitos restritos em algumas horas do dia na carga do sistema eléctrico. Em (Guirelli, 2006) é ilustrado um exemplo de um dia em que houve um jogo de futebol das meias-finais do campeonato do mundo. Esta situação é ilustrada na Figura 2.22. Apesar do efeito significativo deste tipo de eventos na curva de carga, em virtude de serem esporádicos, é muito difícil de serem incorporados em algum modelo de previsão.




Figura 2.21: Curva de carga de uma semana do mês de Maio




Figura 2.22: Curva de carga durante um jogo do campeonato do mundo (Guirelli, 2006)

Em suma, os factores que afectam directamente o nível de consumo são os seguintes:

- Época do ano;
- Tipo de dia da semana;
- Acontecimentos especiais (nomeadamente feriados);



- Hora do dia;
- Condições atmosféricas (principalmente a temperatura);
- Eventos especiais (nomeadamente eventos desportivos e musicais);
- Contexto económico.

## 2.4 Métodos de previsão de consumo

Os sistemas de previsão de carga podem ser classificados de acordo com o horizonte temporal, sendo regularmente divididos em três categorias (Alfares & Nazeeruddin, 2002; Campbell & Adamson, 2006; Feinberg & Genethliou, 2005; Sá, 2013). Essas categorias são:

- Previsão a longo prazo: Consiste numa previsão com horizonte temporal superior a um ano, tornando-se importante numa perspectiva de futuro, permitindo às entidades responsáveis pela manutenção da rede eléctrica terem dados sobre a necessidade de ser necessário fazer investimentos na estrutura da rede ou não.
- Previsão a médio prazo: Consiste numa previsão com horizonte temporal compreendido entre uma semana a um ano. Este tipo de previsão é utilizado, principalmente, como referência para estudos de contingência, programação de intervenções técnicas de manutenção e para negociações no mercado energético entre os agentes de mercado.
- Previsão de curto prazo: Refere-se a previsões que podem ir desde uma hora, um dia, até um período máximo de uma semana. O grande motivo de interesse das STLF centra-se essencialmente na programação de compra/venda de energia entre empresas, análise de segurança e agendamento de operações de manutenção a curto prazo.

De seguida, será apresentado um enquadramento acerca dos métodos de previsão que são normalmente aplicados nos diferentes horizontes temporais descritos antes, procurando-se sintetizar a evolução sentida nas técnicas de previsão de médio/longo prazo, dando um enfoque maior na previsão de curto prazo, uma vez, que é nesse contexto que este trabalho se insere. No que diz respeito aos métodos de STLF serão descritas as técnicas mais utilizadas, tais como, abordagem a dias similares ("*similar day approach*"), métodos de regressão ("*regression models*"), séries temporais ("*time series*") e métodos de Inteli-

gência Artificial (IA) (Campbell & Adamson, 2006; Sousa, 2013). Os modelos de uso final (“*end-use*”) e a modelação econométrica, ou a combinação dos dois, são as abordagens mais utilizadas para as previsões de carga de médio/longo prazo *ibidem* (Campbell & Adamson, 2006; Sousa, 2013).

A previsão por meio de usos finais permite estimar directamente o consumo de energia, utilizando informação diversificada acerca do tipo de equipamento de uso final e também acerca do perfil dos consumidores finais, como por exemplo, idade, dimensão da habitação (Campbell & Adamson, 2006; Feinberg & Genethliou, 2005). Estes modelos são baseados no princípio de que a procura de energia advém da procura dos consumidores para determinados fins específicos, como a iluminação, aquecimento, arrefecimento, entre outros. Os modelos explicam a procura de energia como uma função do número de equipamentos eléctricos existentes no sistema. Este tipo de método de previsão pode apresentar uma boa precisão, embora esteja muito dependente da quantidade e qualidade dos dados disponíveis.

A modelação econométrica procura combinar a teoria económica e as técnicas estatísticas para prever a procura de electricidade. É estimada a relação entre o consumo de energia e os factores que influenciam este consumo, em que estas relações podem ser estimadas através do método dos mínimos quadrados, ou através de métodos baseados em séries temporais.

No que a STLF diz respeito, tem sido desenvolvidos uma grande quantidade de métodos estatísticos e de IA (Campbell & Adamson, 2006; Feinberg & Genethliou, 2005). Nos métodos estatísticos destacam-se a abordagem a dias similares, métodos de regressão e séries temporais. No caso dos métodos de IA, destacam-se as ANN, *Lógica Fuzzy*, *Expert Systems*, *Support Vector Machines* e WNN.

O método de STLF baseado na abordagem a dias similares utiliza uma pesquisa de dados históricos com características semelhantes ao dia a prever. As características podem ser condições meteorológicas, tipo de dia da semana ou uma data específica. Para tornar a previsão mais completa, pode utilizar-se uma combinação linear de um conjunto de dias similares (Feinberg & Genethliou, 2005; Sá, 2013).

Os métodos de regressão pretendem modelar as relações entre o consumo de energia e outros factores como dados climatéricos, tipo de dia e classe de consumidores (Campbell & Adamson, 2006; Hahn, Meyer-Nieberg, & Pickl, 2009; Singh, Ibraheem, Khatoon, Muazzam, & Chaturvedi, 2012; Suganthi & Samuel, 2012). Os métodos de regressão que são recorrentemente utilizados são a regressão linear simples, regressão linear múltipla, regressão exponencial e regressão iterativa (Singh et al., 2012).

As séries temporais são modelos baseados na suposição de que os dados têm uma estrutura interna, como uma autocorrelação, tendência ou variação sazonal (Feinberg & Genethliou, 2005; Singh et al., 2012). Este método possui algumas variantes, como por exemplo, ARMA (*Autoregressive Moving Average*), ARIMA (*Autoregressive Integrated Moving Average*), ARMAX (*Autoregressive Moving Average With Exogenous Variables*) e ARI-MAX (*Autoregressive Integrated Moving Average With Exogenous Variables*).

As redes neurais são implementadas de acordo com o princípio de funcionamento básico de cérebros humanos, como tal, são compostas por vários neurónios. Um neurónio recebe informações sobre os seus nós de entrada e agrega as informações. De seguida determina a sua activação e propaga a sua resposta ao longo do nó de saída para outros neurónios (Hahn et al., 2009). As saídas de uma ANN são algumas das funções matemáticas linear ou não linear das suas entradas. As entradas podem ser as saídas de outros elementos da rede, bem como, entradas de rede reais. A arquitectura de ANN mais popular na STLf é a *Back Propagation*. Em (Hippert, Pedreira, & Souza, 2001) é realizado um estudo extensivo sobre ANN no contexto de STLf.

Um *expert system* é um programa de computador que possui a capacidade de raciocinar, e tem a sua base de conhecimento ampliado conforme novas informações lhe forem disponibilizadas. Os *expert systems*, incorporam normas e procedimentos utilizados por especialistas humanos na área de interesse em software que, assim, tornam o sistema capaz de automaticamente fazer previsões sem assistência humana.

A Lógica Fuzzy, que é baseada na Teoria dos Conjuntos Fuzzy, foi no princípio desenvolvida a partir dos conceitos já estabelecidos pela lógica clássica. A teoria de conjuntos Fuzzy e os coeficientes de lógica Fuzzy são ferramentas que podem ser utilizadas para transformar em termos matemáticos a informação imprecisa captada do meio exterior. Na teoria Fuzzy, os parâmetros de entrada do sistema são mapeados em variáveis linguísticas que são utilizadas na definição de regras para o processamento de variáveis de saída, também representadas por variáveis linguísticas. Desta forma, ao invés de assumir instâncias numéricas, estas variáveis assumem instâncias linguísticas. Segundo (L. C. M. de Andrade, Flauzino, & Silva, 2010) pode-se resumir o sistema de inferência Fuzzy em três fases: fuzzificação, inferência e desfuzzificação.

As *support vector machines* (SVMs) são uma ferramenta de previsão extremamente eficiente para a descoberta de conhecimento, correspondendo a uma nova abordagem na resolução de alguns tipos de problemas, como, problemas de classificação, de regressão, de ranking, etc. As SVMs podem ser definidas como sistemas que utilizam o espaço de hipóteses de uma função linear no espaço hiperdimensional. É possível identificar dois tipos de SVMs (T. M. Ferreira, 2013): os modelos construídos sobre conjuntos de dados

linearmente separáveis e os modelos construídos sobre conjuntos de dados não linearmente separáveis. No trabalho (T. M. Ferreira, 2013) pretende-se estudar e avaliar as SVMs, no sentido de determinar se são uma técnica de mineração de dados para LF em habitações domésticas, tendo-se chegado a resultados satisfatórios.

O método híbrido Wavelet Neural Network foi utilizado pela primeira vez por (Zhang & Benveniste, 1992) mas fora do contexto de LF. Como o próprio nome indica, este método combina a teoria das wavelets com ANN. De uma forma muito simplista, WNN consiste numa ANN do tipo *feed-forward* com uma camada escondida, cuja função de activação dos neurónios é da família wavelet (Pindoriya et al., 2010).

Concluindo, os sistemas que melhor se adequam à previsão de cargas e aqueles que continuam a ser desenvolvidos são os sistemas de IA. Contudo, actualmente, a tendência seguida pelos investigadores é cada vez mais a utilização de um conceito híbrido, aco-  
plando duas ou mais técnicas das enunciadas anteriormente.

**Tabela 2.1: Resumo dos métodos de previsão**

Tipo de Previsão	Métodos de Previsão
Longo/Médio prazo	<ul style="list-style-type: none"> <li>➤ Modelos de uso final</li> <li>➤ Modelação econométrica</li> </ul>
Curto prazo	<ul style="list-style-type: none"> <li>➤ Modelos estatísticos: <ul style="list-style-type: none"> <li>• Dias similares</li> <li>• Métodos de regressão</li> <li>• Séries temporais</li> </ul> </li> <li>➤ Modelos de IA: <ul style="list-style-type: none"> <li>• Redes neuronais</li> <li>• Lógica Fuzzy</li> <li>• Expert systems</li> <li>• Support vector machines</li> <li>• Wavelet neural networks</li> </ul> </li> </ul>

## 3 ESTUDO DE CASO

### 3.1 Dados utilizados na dissertação

Para a realização deste trabalho, de forma a desenvolver e sustentar os métodos de previsão, utilizaram-se dois tipos de dados. Os dados mais importantes, cedidos pela empresa EDP Distribuição, estão relacionados com a informação de consumo da SE de distribuição de Chaves que transforma o nível de alta tensão para média tensão (AT/MT – 60kV/15kV), abastecendo diversos Postos de Transformação (PTs) de média tensão para baixa tensão (MT/BT – 15kV/230/400V), Posto de Transformação Cliente (PTC) e Posto de Transformação Distribuição (PTD), espalhados por toda a região. O segundo tipo de dados é referente a informações meteorológicas, nomeadamente valores de temperatura, na região de Chaves. Estes dados foram fornecidos pelo responsável da estação meteorológica do Aeródromo da cidade de Chaves.

Os dados da SE são referentes ao ano de 2012, desde o dia 1 de Janeiro até 31 de Dezembro, ou seja, 366 dias por se tratar de um ano bissexto. Este conjunto de dados é discriminado de 15 em 15 minutos ao longo de cada dia, perfazendo uma série de 35136 (96 por dia, 366 dias por ano) exemplos de consumo eléctrico verificado. Os dados discriminam os valores de potências (potência activa, reactiva e aparente) nos PTs da SE em causa. Um pequeno excerto da composição do ficheiro de dados fornecido sobre a SE, pode ser visto na Figura 3.1.

Os dados meteorológicos de temperatura são referentes ao mesmo período já indicado no parágrafo anterior, em que neste caso, o conjunto de dados é discriminado de 6 em 6 horas ao longo do dia, perfazendo uma série de 1464 (4 por dia, 366 dias por ano). Também pode ser visto um pequeno excerto da composição do ficheiro na Figura 3.2.

	A	B	C	D	E	F	G	H	I
1	Data_Hora	A_TP1 [kW]	Q_TP1 [kvar]	S_TP1 [kVA]	A_TP2 [kW]	Q_TP2 [kvar]	S_TP2 [kVA]	A_TP1+A_TP2 [kW]	S_TP1+S_TP2 [kVA]
2	20120101 0015	12.680,00	4.570,00	13.478,40	6.890,00	3.100,00	7.555,27	19.570,00	21.033,67
3	20120101 0030	12.590,00	4.560,00	13.390,36	6.820,00	3.100,00	7.491,49	19.410,00	20.881,85
4	20120101 0045	12.580,00	4.610,00	13.398,08	6.790,00	3.090,00	7.460,04	19.370,00	20.858,12
5	20120101 0100	12.510,00	4.600,00	13.328,92	6.810,00	3.120,00	7.490,69	19.320,00	20.819,61
6	20120101 0115	12.370,00	4.480,00	13.156,26	6.720,00	3.080,00	7.392,21	19.090,00	20.548,48
7	20120101 0130	12.200,00	4.460,00	12.989,67	6.540,00	3.010,00	7.199,42	18.740,00	20.189,10
8	20120101 0145	12.150,00	4.500,00	12.956,56	6.490,00	3.030,00	7.162,47	18.640,00	20.119,03

Figura 3.1: Excerto do ficheiro proveniente da empresa EDP Distribuição

F	G	H
name	date, time (UTC)	TL [°C]
Chaves Airport	01-01-2012 03:00	6,4
Chaves Airport	01-01-2012 09:00	7,4
Chaves Airport	01-01-2012 15:00	11,8
Chaves Airport	01-01-2012 21:00	8,2
Chaves Airport	02-01-2012 03:00	6
Chaves Airport	02-01-2012 09:00	10,7
Chaves Airport	02-01-2012 15:00	11,4
Chaves Airport	02-01-2012 21:00	8,1

Figura 3.2: Excerto do ficheiro com dados de temperatura

Com o intuito de aferir a fiabilidade dos dados fornecidos, foi necessário analisá-los com alguma atenção, por forma a corrigir alguns erros ou omissões de leitura que pudessem existir. Este processo de tratamento de dados foi bastante delicado, em virtude do elevado número de elementos existentes.

### 3.2 Caracterização do local

Chaves é um município do distrito de Vila Real, situado na Região Norte de Portugal, mais concretamente na sub-região do Alto Tâmega. Trata-se de uma zona com pouca densidade populacional, como se pode verificar na Figura 3.3, que à semelhança das outras zonas do interior do país, tem perdido população para o litoral. De acordo com dados revelados em (PORDATA, 2015), este município tem 29858 consumidores de energia eléctrica, dos quais, 25436 são do tipo doméstico, 3684 do tipo não-doméstico, 317 da indústria e 421 da agricultura. No que ao consumo de energia diz respeito, pode ser vista na Figura 3.4 os valores referentes ao ano de 2012, donde se verifica que a maior fatia de consumo está relacionado com os consumidores domésticos com um total de 47245816 kWh.

O consumo total de energia foi de 122 GWh, dos quais, 31.5 GWh são referentes à AT, 90 GWh à BT e 12271 kWh ao autoconsumo.

### Chaves (Município)

	2001	2011	2013
População	43.563	41.281	40.788
Superfície em Km2	591,3	591,2	591,2
Freguesias	51	51	39
Idosos por cada 100 jovens	138,6	202,8	215,3
Famílias	15.661	16.163	-
Alojamentos familiares	26.622	28.345	28.434

Figura 3.3: Dados relativos ao município de Chaves (PORDATA, 2015)




Figura 3.4: Consumo de energia eléctrica total e por tipo de consumo (PORDATA, 2015)

### 3.3 Estrutura da rede

A SE de distribuição de Chaves que transforma o nível de alta tensão para média tensão (AT/MT – 60kV/15kV) apresenta uma potência instalada de 60 MVA, estando equipada com dois transformadores, cujos valores de potência não se conseguiu apurar junto da entidade responsável. Cada transformador de potência está ligado a um barramento, com as várias saídas para PTC e PTD. Como já foi referido anteriormente, existe uma hierarquia de equipamentos que se sucedem na rede de distribuição, que pode ser esquematizada da forma ilustrada na Figura 3.5. A montante desta instalação, a RNT é do domínio da REN. Na Figura 3.6 apresenta-se uma pequena ilustração da RNT nesta área geográfica.

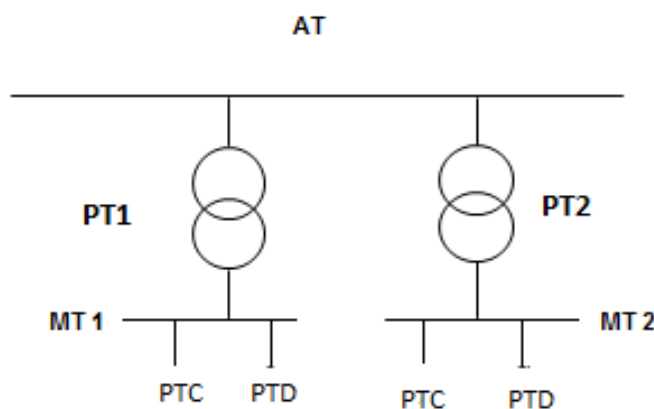


Figura 3.5: Topologia da rede de distribuição



Figura 3.6: Excerto da Rede Nacional de Transporte. Adaptado ("REN - Eletricidade," 2015)

De seguida, na Tabela 3.1, apresentam-se algumas características quantitativas relacionadas com a estrutura da rede. Estes dados só vêm comprovar os factos enumerados no ponto anterior, na medida, que comprovam estarmos perante uma zona onde o consumo é predominantemente ao nível de clientes de BT residencial.



Tabela 3.1: Dados da rede fornecidos pela empresa EDP Distribuição

Item	PT1 (barramento 1)	PT2 (barramento 2)	Total (PT1 + PT2)
PTC	38	24	62
PTD	192	128	320
Cientes BT	17389	9654	27043
Cientes MT	36	22	58
Potência instalada PTC	18735	3696	22431
Potência instalada PTD	70475	13696	84171
Potência instalada total	89210	17392	106602

É de referir que não se faz referência a nenhum tipo de PRE integrada nesta rede, na medida, que não foi possível apurar informações sobre o número e tipo de PREs existentes nesta rede de distribuição.

### 3.4 Factores condicionantes do diagrama de carga

No ponto 2.3 deste trabalho já foram referidos alguns factores que podem influenciar o consumo, como tal, esta SE não é nenhuma excepção à regra, logo os factores que contribuem para um aumento ou diminuição do consumo de energia serão os mesmos evidenciados anteriormente.

Após ter sido executada uma tarefa exaustiva de cruzamento de dados entre os valores de consumo disponibilizados e os possíveis factores condicionantes do diagrama de carga activa, chegou-se à conclusão, que os principais factores com especial relevância no consumo para realizar um sistema de previsão de curto prazo nesta SE, são a temperatura, o tipo de dia da semana e acontecimentos especiais (feriados).

### 3.4.1 Temperatura

A partir dos dados de temperatura fornecidos, foi criada uma tabela com o valor de temperatura média associado a cada dia do ano. Este valor foi calculado através da média aritmética simples dos dados de temperatura referentes a cada dia, de acordo com a seguinte expressão:

$$T_{media} = \frac{T_{3h} + T_{9h} + T_{15h} + T_{21h}}{4} \quad (3.1)$$

onde,  $T_{3h}$ ,  $T_{9h}$ ,  $T_{15h}$ ,  $T_{21h}$  corresponde à temperatura em graus Celcius registada às 3, 9, 15 e 21 horas de cada dia. A tabela resultante deste processo apresenta o aspecto mostrado na Figura 3.7 e a representação gráfica apresentada na Figura 3.8.

	A	B	C
1	Dia ano	date, time (UTC)	TMed [°C]
2	1	01-01-2012	8,5
3	2	02-01-2012	9,1
4	3	03-01-2012	7,9
5	4	04-01-2012	8,0
6	5	05-01-2012	8,0
7	6	06-01-2012	3,6
8	7	07-01-2012	4,8
9	8	08-01-2012	2,0
10	9	09-01-2012	2,9
11	10	10-01-2012	1,8

Figura 3.7: Excerto da tabela das temperaturas médias de cada dia do ano

Após serem combinadas as temperaturas com os respectivos dias e consumos verificados, foi possível esboçar o gráfico que permite aferir sobre a influência que a temperatura teve nos valores de carga verificados.

No gráfico ilustrado na Figura 3.9, cada ponto representa um valor de ponta que o consumo assumiu num determinado instante durante o ano de 2012. No eixo das abcissas, é possível ler a temperatura média em graus Celsius, enquanto nas ordenadas estão os valores de potência activa verificados a cada intervalo de 15 minutos. Através da análise gráfica é possível registar uma tendência linear negativa, mostrando que à medida que a temperatura vai aumentando, os valores de carga vão gradualmente diminuindo, desta forma, verifica-se uma clara influência da temperatura no consume eléctrico.

Esta influência poderá ter explicação, devido à elevada quantidade de dispositivos de aquecimento ligados ao mesmo tempo nos dias de inverno mais frios, que de um modo

geral, apresentam consumos elevados. Um levantamento local dos equipamentos de uso final para aquecimento, poderia manifestar-se neste estudo como um contributo interessante, para despistar, se é de facto a electricidade o recurso mais comum para esta finalidade. Por outro lado, com temperaturas mais elevadas, a tendência típica em zonas desenvolvidas é a de existir um aumento de consumo de electricidade, devido à utilização de sistemas de refrigeração.




Figura 3.8: Temperatura média em Chaves no ano 2012




Figura 3.9: Relação entre a temperatura e o consumo ocorrido na SE durante o ano 2012

### 3.4.2 Tipo de dia da semana

Outro dos factores que quotidianamente pode influenciar o consumo eléctrico é o dia da semana em que ele é registado. Culturalmente, a semana traduz um ciclo de 7 dias que se repetem infinitamente, dando origem a certos hábitos de rotina nas populações.

Um exemplo de consumo de uma semana típica no local em causa pode ser visto na ilustração seguinte (Figura 3.10). É bem visível que o consumo de segunda a sexta-feira é bastante parecido, destacando-se do sábado e domingo. Este facto é perfeitamente normal e habitual, em virtude de ao fim de semana existir um abrandamento das actividades industriais e comerciais.




Figura 3.10: Diagrama de carga semanal

Os dias feriado, no caso de acontecerem durante os cinco dias úteis da semana, também influenciam o consumo, na medida que o feriado condiciona a rotina diária e, consequentemente os comportamentos relacionados ao consumo. Se o posicionamento destes dias for contíguo ao fim de semana, dá origem a períodos mais alargados de redução de actividade económica. O dia feriado, em virtude de possuir um diagrama de carga atípico, podem ser um problema bastante grande para qualquer sistema de previsão.

## 4 MODELOS DE PREVISÃO PROPOSTOS

### 4.1 Ferramentas utilizadas

Para o desenvolvimento desta dissertação, tanto na análise e tratamento dos dados como na implementação dos modelos de previsão, foi utilizado o *software Excel 2010* da *Microsoft Office®* e o poderoso *software MATLAB R2012a* da *MathWorks®*. As ferramentas e funcionalidades inerentes aos *software* utilizados foram determinantes para a construção de um modelo totalmente automatizado, destinado a resolver os objectivos a que nos propusemos. Dentro dos *software* utilizados, deve ser destacada a importância da *Wavelet Toolbox* (Misiti et al., 2001, 2013), sem a qual seria praticamente impossível realizar este trabalho.

### 4.2 Estrutura das variáveis de entrada do sistema de previsão

Numa primeira fase foi necessário realizar um pré-processamento dos dados, de forma a eliminar ou corrigir dados atípicos e registos em falta, aos quais as redes são muito sensíveis.

Depois de os dados estarem todos corrigidos e normalizados, partiu-se para a definição da estrutura de dados relativamente às variáveis de entrada que melhor serviriam para desenvolver o sistema de previsão. Depois de alguns testes realizados com os dados fornecidos e, também de acordo com os factores que condicionam o diagrama de carga que foram enunciados na secção 3.4, chegou-se ao formato apresentado na Tabela 4.1. Uma ilustração dessa estrutura é apresentada na Figura 4.1.

As variáveis têm o seguinte significado:

- Dia ano – dia do ano [1 ; 366], por 2012 ter sido uma ano bissexto;
- Hora – hora do dia [0,15 ; 24];
- Dia semana – tipo de dia da semana [1 ; 7], onde 1 corresponde a segunda feira e 7 a domingo;
- Feriado – indicação se o dia corresponde a um feriado [0 ; 1], onde 0 corresponde a um dia normal e 1 corresponde a dia feriado;
- A\_TP1 – valores de potência activa do PT 1;
- A\_TP2 – valores de potência activa do PT 2;
- A\_TP1+A\_TP2 – volume total de potência activa na SE;
- Tmed – temperaturas médias de cada dia anterior ao dia de previsão e também do próprio dia;
- Dia – dia do mês [1 : 31];
- Mês – mês do ano [1 ; 12].

**Tabela 4.1: Candidatas a variáveis de entrada do sistema de previsão**

Dia ano	Hora	Dia semana	Feriado	A_TP1	A_TP2	A_TP1+A_TP2	Tmed	Dia	Mês
------------	------	---------------	---------	-------	-------	-------------	------	-----	-----

B	C	D	E	F	G	H	I	J	K
Dia ano	Hora	Dia semana	Feriado	A_TP1 [kW]	A_TP2 [kW]	A_TP1+A_TP2 [kW]	Tmed	Dia	mês
1	0,15	7	1	12.680,00	6.890,00	19.570,00	8,5	1	1
1	0,30	7	1	12.590,00	6.820,00	19.410,00	8,5	1	1
1	0,45	7	1	12.580,00	6.790,00	19.370,00	8,5	1	1
1	1,00	7	1	12.510,00	6.810,00	19.320,00	8,5	1	1
1	1,15	7	1	12.370,00	6.720,00	19.090,00	8,5	1	1
1	1,30	7	1	12.200,00	6.540,00	18.740,00	8,5	1	1
1	1,45	7	1	12.150,00	6.490,00	18.640,00	8,5	1	1
1	2,00	7	1	11.940,00	6.410,00	18.350,00	8,5	1	1
1	2,15	7	1	11.680,00	6.280,00	17.960,00	8,5	1	1
1	2,30	7	1	11.490,00	6.130,00	17.620,00	8,5	1	1

**Figura 4.1:** Ilustração da folha de cálculo *Excel* com a estrutura das variáveis de entrada

Após o tratamento e criação da tabela de dados necessários para o desenvolvimento e implementação do sistema estar concluída no *Excel*, foi necessário realizar a importação para o ambiente *Matlab*.

### 4.3 Modelos de previsão propostos


Para alcançar o objectivo proposto de desenvolver um STLFI com recurso a wavelet, foram desenvolvidos dois modelos diferentes. Ambos possuem os mesmos algoritmos de previsão, mas diferem entre si em relação à forma como as wavelets são utilizadas para a decomposição e filtragem dos dados relativos ao consumo de potência activa. No que ao resultado final diz respeito, ambos os modelos apresentam a previsão em termos de potência e energia.

#### 4.3.1 Primeiro modelo de previsão

Com o objectivo de filtrar o sinal de entrada referente aos dados de consumo, decidiu-se utilizar neste modelo a TWD que vai decompor o sinal em várias componentes, para posteriormente serem utilizados no algoritmo de previsão. Este processo tem a vantagem de diminuir a quantidade de informação sem deformar a essência do seu conteúdo. Assim, a transformada de wavelet além de permitir a filtragem de dados, permite a sua compactação.

Após alguns testes e também de acordo com um exemplo importante apresentado em (Misiti et al., 2001), que apresenta bons resultados na filtragem de sinais eléctricos com um determinado tipo de função wavelet, decidiu-se a utilização da função Daubechies da família wavelet como função de discretização na TWD. Mais especificamente, utilizou-se a função Daubechies de ordem 2 (db2, Figura 4.2) com 3 níveis de filtragem, o que significa, que o sinal original vai ser decomposto 3 vezes, originando a criação de 3 coeficientes de detalhe e aproximação. Um exemplo desta decomposição é ilustrado na Figura 4.4, em que a curva de carga de um dia com 96 valores vai ser decomposta numa primeira vez para 48 valores, depois para 24 e no fim para 14 valores.

Escolheu-se o coeficiente de segunda ordem para posteriormente se utilizar no algoritmo de previsão, não só por apresentar um bom nível de detalhe, mas também devido a ser composto por 24 valores, o que facilita em termos do cálculo da energia, uma vez, que nesta situação o vector com 24 valores de consumo de energia irá ser a imagem directa dos 24 valores de potência activa.



**Figura 4.2: Função Wavelet Daubechies de ordem 2**

Uma análise sumária da estrutura deste modelo pode ser vista na Figura 4.3.



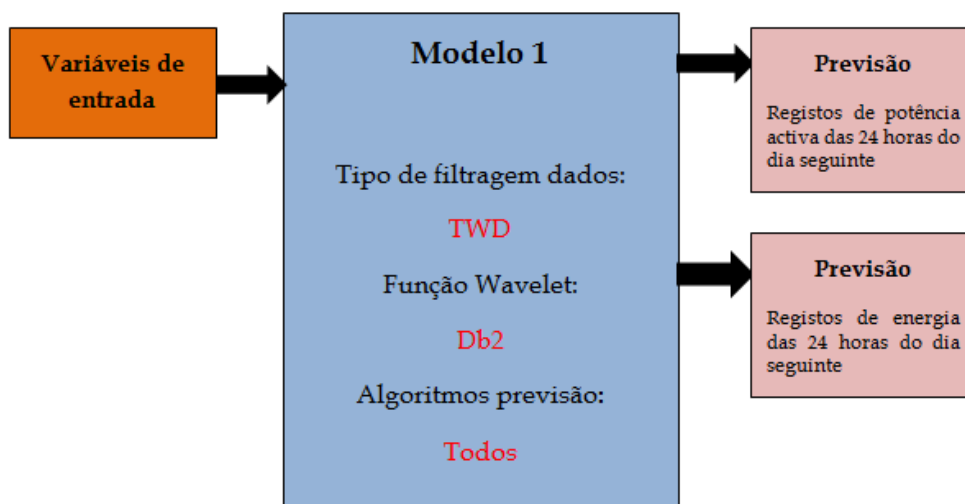


Figura 4.3: Primeiro modelo para STL

No Anexo 2, pode ser consultado um excerto de código Matlab da TWD utilizada neste modelo de previsão.




Figura 4.4: Exemplo de TWD com função db2 e 3 níveis de decomposição

### 4.3.2 Segundo modelo de previsão

Neste segundo modelo, ao invés de se utilizar uma decomposição dos dados como no modelo anterior, utiliza-se uma funcionalidade da *Wavelet Toolbox* denominada *Matching Pursuit* (MathWorks, 2015), que permite filtrar um sinal através de uma aproximação com o detalhe e função wavelet desejada.

Após alguns testes e também de acordo com um exemplo importante apresentado em (MathWorks, 2015), decidiu-se a utilização da função Daubechies da família wavelets como função de aproximação. Mais especificamente, utilizou-se a função Daubechies de ordem 4 (db4, Figura 4.5) com 2 níveis de filtragem. Um exemplo desta filtragem com aproximação de wavelet é ilustrado na Figura 4.6. É visível que o sinal aproximado fica sem as transições bruscas que continha, factores que dificultam na aplicação de algoritmos de previsão.




Figura 4.5: Função Wavelet Daubechies de ordem 4

Neste caso, como não existe redução do número de coeficientes, o cálculo da energia horária é efectuado pela integração da curva de potência activa, o que se traduz pela seguinte expressão:

$$E = \sum_{n=1}^4 P_n \times 0,25 \text{ MWh}, \quad (4.1)$$

onde  $E$  é a anergia calculada em MWh,  $n$  é o índice das 4 divisões de cada hora (intervalos de 15 minutos) e  $P_n$  é a potência filtrada no instante  $n$  em kW.




Figura 4.6: Exemplo de uma aproximação com função wavelet db4

Uma análise sumária da estrutura deste modelo pode ser vista na Figura 4.7.

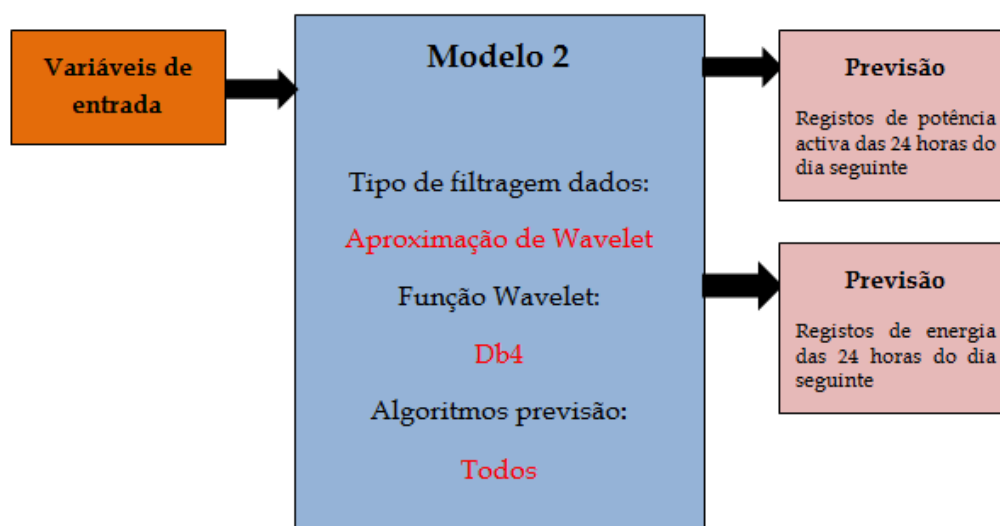


Figura 4.7: Segundo modelo para STLF

### 4.3.3 Algoritmos de previsão

Ao longo deste trabalho foram desenvolvidos quatro algoritmos de previsão, sendo que três deles utilizam os valores de temperatura, enquanto o outro algoritmo não.

Os algoritmos propostos são assentes em métodos aritméticos e combinatórios, baseados em dias similares que tivessem alguma influência directa no dia que se pretende efectuar a previsão. Optou-se por este tipo de abordagem, dado que o horizonte temporal da previsão é extremamente curto (dia-seguinte). Das análises de correlação efectuadas nas secções 2.3, 2.4 e 3.4, verificou-se que a utilização referente aos dias anteriores até um horizonte máximo de 7 dias revela-se um contributo de grande importância, já que se confirma que o dia a prever tem um padrão de consumo próximo de um dia de semana idêntico ocorrido recentemente. O efeito de quebra de consumo durante os fins-de-semana e dias especiais, condiciona a autocorrelação evidenciada quando se impõe atrasos de 48 horas. Nesse sentido, foi adoptada uma estratégia de combinação de dias a incluir na construção daquilo a que se irá chamar de “matriz de previsão”.

A construção da matriz de previsão é realizada da mesma forma para os quatro algoritmos. Esta matriz vai ser composta pelos dados de potência activa já previamente decompostos ou filtrados, dependendo do modelo de previsão escolhido. Os dados de potência utilizados na matriz previsão variam tendo em conta o tipo de dia a prever, e se estamos perante um dia feriado ou não. O preenchimento da referida matriz é realizado de acordo com as combinações apresentadas nas Tabelas 4.2 e 4.3, onde o símbolo “-” significa que os dados referentes a esse dia não são utilizados, e “x” significa que os dados são utilizados. De forma a simplificar o algoritmo, optou-se por equiparar os dias feriados com os fins-de-semana.

**Tabela 4.2: Matriz de previsão para dias não feriado**

Tipo de dia a prever (D)	Feriado	Matriz de previsão						
		D-1	D-2	D-3	D-4	D-5	D-6	D-7
1 (2 <sup>a</sup> )	0	-	-	x	x	x	x	x
2 (3 <sup>a</sup> )	0	x	-	-	x	x	x	x
3 (4 <sup>a</sup> )	0	x	x	-	-	x	x	x
4 (5 <sup>a</sup> )	0	x	x	x	-	-	x	x

<b>5 (6ª)</b>	0	x	x	x	x	-	-	x
<b>6 (sab)</b>	0	-	-	-	-	-	x	x
<b>7 (dom)</b>	0	x	-	-	-	-	-	x

Tabela 4.3: Matriz de previsão para dias feriado

Tipo de dia a prever (D)	Feriado	Matriz de previsão						
		D-1	D-2	D-3	D-4	D-5	D-6	D-7
<b>1 (2ª)</b>	1	x	x	-	-	-	-	-
<b>2 (3ª)</b>	1	-	x	x	-	-	-	-
<b>3 (4ª)</b>	1	-	-	x	x	-	-	-
<b>4 (5ª)</b>	1	-	-	-	x	x	-	-
<b>5 (6ª)</b>	1	-	-	-	-	x	x	-
<b>6 (sab)</b>	1	-	-	-	-	-	x	x
<b>7 (dom)</b>	1	x	-	-	-	-	-	x

Os quatro algoritmos desenvolvidos são os seguintes:

- **Sem temperatura:** Este algoritmo não contempla qualquer valor de temperatura, desta forma, traduz o seu resultado através da média aritmética simples (ponto a ponto) entre todos os blocos de dados da matriz de previsão (Figura 4.8). O modelo de funcionamento deste algoritmo é apresentado na Figura 4.9;

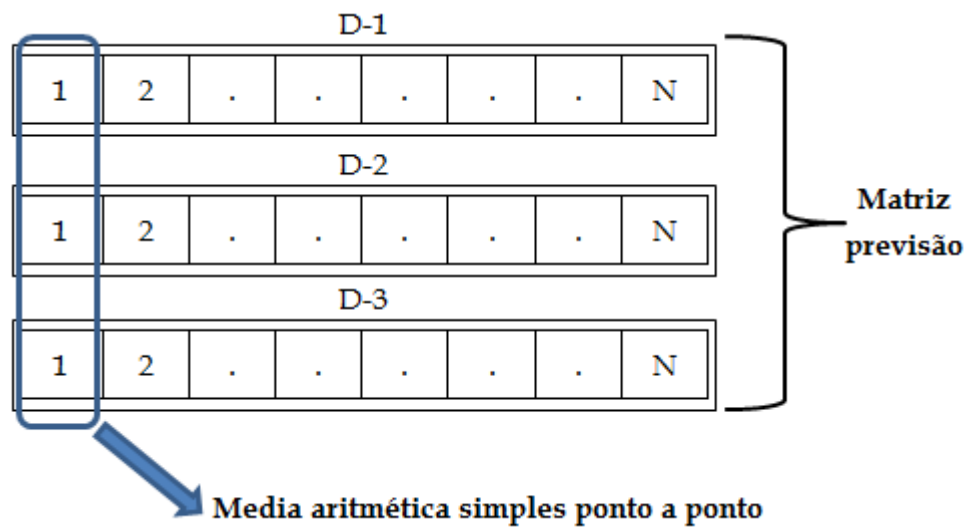


Figura 4.8: Ilustração do cálculo da média utilizada nos algoritmos




Figura 4.9: Arquitectura do algoritmo Sem temperatura

- Max temperatura: Este algoritmo já faz a previsão utilizando os valores de temperatura. Neste caso, o valor da previsão vai-se traduzir pela média aritmética simples somada em cada ponto por um factor de correcção. O modelo de funcionamento deste algoritmo e dos restantes é apresentado na Figura 4.10 . O cálculo deste factor de correcção tem 5 etapas que são:

- 1) Criação de uma tabela, em que cada coluna corresponde ao valor da diferença entre a temperatura média do dia a prever e o valor dos dias presentes na matriz de previsão;
- 2) Calcula-se o índice do maior valor de diferença de temperatura da tabela anterior;
- 3) Criação de outra tabela, em que cada coluna corresponde ao valor da diferença entre a média aritmética simples inicial e o valor de cada

dia presente na tabela de previsão, em que todas estas diferenças são feitas ponto a ponto;

- 4) Calcula-se a média de cada coluna da matriz das diferenças anterior, donde resulta uma matriz com uma linha e várias colunas;
- 5) O factor de correcção vai corresponder ao valor que estiver na coluna da matriz obtida em 4), cuja posição é a do índice calculado no ponto 2).

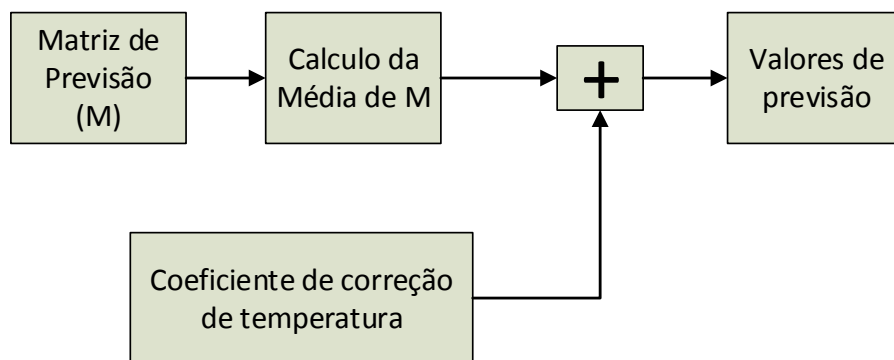


Figura 4.10: Arquitectura dos algoritmos que utilizam temperatura

- Min temperatura: Este algoritmo faz a previsão utilizando os valores de temperatura. Neste caso, o valor da previsão vai-se traduzir pela média aritmética simples somada em cada ponto por um factor de correcção. O factor de correcção é calculado de forma análoga ao algoritmo anterior, com a pequena diferença que no ponto 2) calcula-se o índice do menor valor de diferença de temperatura. Para melhor compreensão, pode ser visto um excerto do código deste algoritmo no Anexo 5.
- Max\_Min temperatura: Neste caso o factor de correcção vai ser um valor intermédio entre o índice do maior valor de diferença de temperatura e o de menor. Para melhor compreensão, pode ser visto um excerto do código deste algoritmo no Anexo 6.

## 4.4 Simulações e resultados

Para uma avaliação do desempenho dos modelos de previsão, pode-se pensar em termos do erro médio quadrado ou da soma de erros quadrados médios obtidos com comparação entre o valor previsto e o valor real.

Normalmente, para aferir o desempenho dos sistemas de previsão são utilizados indicadores que estão inseridos no lote dos denominados erros de regressão, sendo eles, o Erro Quadrático Médio (MSE – *mean squared errors*), Erro Absoluto Médio (MAE – *mean absolute error*) e a Percentagem Absoluta Média do Erro (MAPE – *mean absolute percentage error*). As expressões que definem este tipo de métodos são as seguintes:

- Erro Quadrático Médio (MSE)

$$MSE(f) = \frac{1}{ne} \sum_{i=1}^{ne} (y_i - \hat{y}(f))^2 \quad (4.2)$$

Onde,  $ne$  corresponde ao número de exemplos da amostra utilizada,  $y_i$  o valor verificado e  $\hat{y}$  o valor previsto.

- Erro Absoluto Médio (MAE)

$$MAE(f) = \frac{1}{ne} \sum_{i=1}^{ne} |y_i - \hat{y}(f)| \quad (4.3)$$

- Percentagem Absoluta Média do Erro (MAPE)

$$MAPE(\%) = \frac{\sum_{i=1}^{ne} \left| \frac{\hat{y} - y_i}{y_i} \right|}{ne} \times 100 \quad (4.4)$$

Estes 3 índices de erros transmitem diferentes tipos de informação sobre a previsão ocorrida. Comparando o MSE com o MAE, verifica-se que o valor do 2º é menos sensível à existência de casos excepcionais para os quais a previsão se afaste, de uma forma explícita, do valor de saída verificado. No domínio da previsão de curto prazo, é usual que de vez em quando existam dias onde se verifique um pico de consumo anormal e que seja dificilmente previsto com exactidão. O parâmetro mais divulgado e utilizado em toda a literatura é o MAPE.



Para avaliar a precisão dos resultados obtidos será utilizado o MAE e o MAPE, mas com especial foco neste último.

Nas duas secções seguintes serão apresentados os resultados das inúmeras simulações efectuadas dos dois modelos de previsão desenvolvidos, com a finalidade de aferir sobre a qualidade dos mesmos. Também serão mostradas algumas ilustrações do *output* gerado a quando de uma simulação do sistema desenvolvido.

#### 4.4.1 Primeiro modelo de previsão

Depois de se terem simulado praticamente todos os dias do ano, com excepção dos primeiros 8 dias do mês de Janeiro, em virtude do sistema utilizar num máximo os 7 dias anteriores ao dia a prever, e também de alguns dias ao longo do ano em que os dados estavam de certa forma corrompidos, registaram-se os resultados relativos ao primeiro modelo de previsão apresentados nas tabelas e figuras seguintes.

Na Tabela 4.4 apresenta-se os valores de MAE e MAPE médios de cada mês ao longo do ano de 2012 (Figura 4.11), enquanto na Tabela 4.5 já só se mostra o valor médio anual dos erros calculados a partir da tabela anterior.

**Tabela 4.4: Valores médios diários de cada mês**

Mês	Previsão com coeficientes de Wavelet							
	Sem temperatura		Max temperatura		Min temperatura		Max_Min temperatura	
	MAE (kW)	MAPE (%)	MAE (kW)	MAPE (%)	MAE (kW)	MAPE (%)	MAE (kW)	MAPE (%)
1	925,0	4,931	990,4	5,304	1114,5	5,973	874,6	4,668
2	1009,2	5,944	1135,4	6,729	1182,6	6,850	1048,0	6,184
3	1032,5	7,956	1133,9	8,723	1164,2	9,021	988,9	7,621
4	1179,4	9,344	1363,9	10,650	1231,5	9,726	1150,6	8,973
5	901,8	8,198	921,8	8,376	1031,8	9,286	913,0	8,283
6	762,7	6,966	853,1	8,066	1003,1	9,175	800,9	7,335
7	731,4	6,352	901,4	7,935	918,2	7,937	802,0	6,991
8	842,5	6,735	685,0	5,534	1233,7	9,877	821,6	6,575
9	776,5	7,424	873,9	8,243	939,6	9,035	803,1	7,730
10	923,1	7,656	901,0	7,929	1218,9	9,971	1007,4	8,269
11	1159,0	7,949	1230,8	8,549	1339,9	9,104	1158,4	7,950
12	1299,2	7,802	1255,3	7,485	1619,6	9,837	1334,8	8,034

Tabela 4.5: Média diária anual

	Previsão com coeficientes de Wavelet							
	Sem temperatura		Max temperatura		Min temperatura		Max_Min temperatura	
Anual	MAE (kW)	MAPE (%)	MAE (kW)	MAPE (%)	MAE (kW)	MAPE (%)	MAE (kW)	MAPE (%)
2012	961,9	7,27	1020,5	7,78	1166,5	8,82	975,3	7,38




Figura 4.11: Ilustração gráfica da Tabela 4.4

Na Tabela 4.6 apresenta-se o resultado referente ao melhor dia de cada mês com todos os algoritmos de previsão utilizados. Nas figuras seguintes será ilustrado o *output* duma simulação do sistema de previsão para este modelo, sendo que neste caso será a simulação com o melhor resultado de todos os algoritmos, que corresponde ao dia 18 de Dezembro.

Na Figura 4.12 está representado o valor médio do MAPE relativo a cada dia da semana durante todo o ano para todos os algoritmos de previsão implementados e testados.

Tabela 4.6: Melhor dia de cada mês

Mês	Melhor dia do mês			
	Sem Temperatura	Max Temperatura	Min Temperatura	Max_Min Temperatura
Mês	MAPE (%)	MAPE (%)	MAPE (%)	MAPE (%)
1	2,249	2,851	2,878	2,347
2	2,234	2,562	2,647	2,033
3	2,995	2,510	3,834	3,086
4	4,621	4,451	4,401	4,655
5	3,502	3,041	3,114	3,395
6	2,942	3,792	3,316	3,464
7	2,777	2,933	3,005	2,861
8	2,129	2,411	3,266	2,154
9	2,107	3,127	2,047	3,140
10	1,971	2,445	3,326	2,696
11	3,853	3,909	3,312	3,342
12	1,963	3,870	3,336	2,474




Figura 4.12: Valor médio do MAPE de cada tipo de dia da semana




Figura 4.13: Ilustração gráfica dos valores de carga previstos e registados para o modelo 1




Figura 4.14: Ilustração gráfica dos valores de energia previstos e registados para o modelo 1




Figura 4.15: Valor do MAPE em cada ponto durante a previsão para o modelo 1




Figura 4.16: Histograma da diferença entre o valor previsto e o registado para o modelo 1

```
>> testes
Dia a prever (DD/MM): 18/12 terça feira!!!

mae =

    361.0077

mape =

    1.9629
```

**Figura 4.17: Mensagem apresentada na consola do Matlab para uma simulação do modelo 1**

Nas Figuras 4.13 a 4.17 está ilustrado todo o tipo de resultados apresentados no final de cada simulação efectuada, com o propósito de prever o consumo de energia do dia seguinte com recurso a wavelet. A Figura 4.13 representa graficamente o vector dos 24 valores previstos de consumo de potência activa, enquanto a Figura 4.14 apresenta-se o vector da previsão de energia. Neste caso são idênticos, pelos motivos já enunciados na secção 4.3.1.

A Figura 4.15 ilustra a variação do erro MAPE durante todo o dia de previsão, em termos percentuais, ou seja, o gráfico cresce ou decresce conforme o erro for maior ou menor. Já a Figura 4.16 apresenta a diferença entre o valor previsto e registado, mas ao nível de consumo.

Por fim, a Figura 4.17 refere-se ao *output* ao nível da consola no ambiente Matlab, em que se indica o mês e o dia que se está a prever, bem como o tipo de dia de semana. Também se indica os valores numéricos exactos do MAE e MAPE, para se poder ter uma noção mais exacta que ao nível gráfico não se consegue ter.

Em relação aos resultados obtidos por este modelo de previsão, podemos dizer que são bastante satisfatórios, na medida que não existe nenhum valor de erro médio absoluto de previsão superior a 10%, quer em termos de média mensal e média anual. Mas como o objectivo deste trabalho é fazer previsão a curto prazo, temos de dar destaque aos valores atingidos para os melhores dias de cada mês que apresentam todos um MAPE inferior a 5%, facto que está dentro da média dos sistemas de previsão existentes com um horizonte de previsão a 24 horas.

Não se pode dizer que existe algum dos algoritmos de previsão que se destaque muito entre eles, porque os resultados obtidos são parecidos, não existindo nenhum que consiga evidenciar-se de forma constante.

#### 4.4.2 Segundo modelo de previsão

Depois de efectuar as várias simulações com os mesmos dias que no modelo anterior, este segundo modelo apresentou os resultados discriminados a seguir nas várias tabelas e figuras.

Tabela 4.7: Valores médios diários de cada mês

Mês	Previsão com aproximação de Wavelet							
	Sem temperatura		Max temperatura		Min temperatura		Max_Min temperatura	
	MAE (kW)	MAPE (%)	MAE (kW)	MAPE (%)	MAE (kW)	MAPE (%)	MAE (kW)	MAPE (%)
1	968,6	5,037	1006,5	5,247	1217,0	6,348	969,0	5,030
2	1036,6	5,930	1195,7	6,873	1203,2	6,776	1100,6	6,210
3	944,7	6,995	1136,9	8,382	1102,5	8,179	990,6	7,289
4	1059,7	8,005	1244,0	9,236	1187,4	8,886	1109,8	8,280
5	851,7	7,425	879,9	7,680	1011,8	8,692	866,4	7,525
6	830,0	7,250	949,1	8,304	1142,4	9,981	908,7	7,890
7	736,3	6,211	807,6	6,839	838,3	7,065	748,6	6,314
8	889,3	6,778	767,2	5,967	1311,6	9,972	881,2	6,741
9	795,9	7,265	909,2	8,266	924,5	8,441	826,0	7,569
10	1005,6	7,938	947,5	7,606	1333,6	10,399	1076,0	8,439
11	1102,4	7,243	1169,7	7,795	1301,5	8,424	1546,2	7,459
12	1264,8	7,490	1211,2	7,131	1576,4	9,496	1272,1	7,566




Figura 4.18: Ilustração gráfica da Tabela 4.7

Tabela 4.8: Média diária anual

	Previsão com coeficientes de Wavelet							
	Sem temperatura		Max temperatura		Min temperatura		Max_Min temperatura	
Anual	MAE (kW)	MAPE (%)	MAE (kW)	MAPE (%)	MAE (kW)	MAPE (%)	MAE (kW)	MAPE (%)
2012	957,1	6,96	1018,7	7,44	1179,2	8,55	1024,6	7,19

Na Tabela 4.7 apresenta-se os valores de MAE e MAPE médios de cada mês ao longo do ano de 2012, estando depois representados graficamente na Figura 4.18. A Tabela 4.8 apresenta o valor médio anual dos erros calculados a partir da tabela anterior. Na Tabela 4.9 apresenta-se o resultado referente ao melhor dia de cada mês com todos os algoritmos de previsão utilizados.

Tabela 4.9: Melhor dia de cada mês

	Melhor dia do mês			
	Sem Temperatura	Max Temperatura	Min Temperatura	Max_Min Temperatura
Mês	MAPE (%)	MAPE (%)	MAPE (%)	MAPE (%)
1	1,996	2,316	2,347	2,348
2	2,202	2,003	2,731	1,773
3	2,744	2,340	2,661	2,550
4	4,545	3,473	4,434	4,253
5	3,011	2,715	3,415	3,011
6	2,884	4,409	3,239	2,884
7	2,656	2,357	2,808	2,497
8	2,635	2,446	3,226	1,839
9	2,156	2,582	2,058	2,071
10	2,806	2,232	3,252	1,931
11	4,075	2,946	2,982	2,675
12	2,245	3,004	3,081	2,458

Na Figura 4.19 está representado o valor médio do MAPE relativo a cada dia da semana durante todo o ano para todos os algoritmos de previsão implementados e testados, em que se evidencia um erro inferior para a terça-feira e quinta-feira em todos os algoritmos.






Figura 4.19: Valor médio do MAPE de cada tipo de dia da semana

De forma análogo ao modelo anterior, nas figuras seguintes será ilustrado o *output* duma simulação do sistema e previsão para este modelo para o dia com o melhor resultado de todos os algoritmos, que corresponde ao dia 13 de Fevereiro.




Figura 4.20: Ilustração gráfica dos valores de carga previstos e registados para o modelo 2




Figura 4.21: Ilustração gráfica dos valores de energia previstos e registados para o modelo 2




Figura 4.22: Valor do MAPE em cada ponto durante a previsão para o modelo 2




Figura 4.23: Histograma da diferença entre o valor previsto e o registado para o modelo 2

```
>> testes11_1
Dia a prever (DD/MM): 13/2 segunda feira!!!

mae_maxmintemp =

    359.9324

mape_maxmintemp =

    1.7725
```

Figura 4.24: Mensagem apresentada na consola do Matlab para uma simulação do modelo 2

Nas Figuras 4.20 a 4.24 está ilustrado todo o tipo de resultados apresentados no final de cada simulação efectuada com este modelo de previsão. Neste caso, as figuras 4.20 e 4.21 já são diferentes, porque neste modelo os valores de energia tiveram de ser calculados através da equação 4.1.

A Figura 4.22 ilustra a variação do erro MAPE durante todo o dia de previsão, em termos percentuais, ou seja, o gráfico cresce ou decresce conforme o erro for maior ou menor. Já a Figura 4.23 apresenta a diferença entre o valor previsto e registado, mas ao nível de consumo. Por fim, a Figura 4.24 ilustra os mesmos conteúdos já descritos na Figura 4.17 do ponto anterior.

Em relação aos resultados obtidos por este modelo de previsão, são as mesmas que já foram enunciadas para o modelo anterior, como consequência de os resultados serem globalmente iguais.

#### 4.4.3 Comparação entre os modelos desenvolvidos

Observando atentamente a Figura 4.25 e 4.26 constata-se que os resultados de previsão de ambos os modelos são bastante semelhantes em todas as variantes, não existindo um modelo ou algoritmo que se destaque de sobremaneira em relação aos outros.

Note-se que, de todos os dias testados, a previsão mais acertada para o primeiro modelo corresponde ao algoritmo que não faz uso da temperatura. Pelo contrário, no segundo modelo, a previsão mais acertada corresponde a um algoritmo que utiliza a temperatura.




Figura 4.25: Comparação entre os valores médios diários anuais do MAE para os dois modelos de previsão




Figura 4.26: Comparação entre os valores médios diários anuais do MAPE para os dois modelos de previsão

No caso de ter que se escolher um destes dois modelos com o respectivo algoritmo para aplicar no caso de estudo, iria ser escolhido o primeiro modelo que faz a previsão através dos coeficientes de wavelet com o algoritmo sem temperatura, escolha esta, que é tomada face a todos os resultados obtidos. Outra alternativa que até pode ser desenvolvida num trabalho futuro, seria a utilização de um modelo híbrido integrando os dois modelos num só, em que dependendo de alguns factores, como o mês, dia de semana, temperatura, seria seleccionado o modelo a utilizar, podendo assim, maximizar as potencialidades de cada um.

Um aspecto a salientar, reside na rapidez que ambos os modelos propostos para implementar o sistema de previsão levam para apresentar o resultado, como consequência do volume de informação necessário.



## 5 CONCLUSÕES E TRABALHO FUTURO

### 5.1 Conclusões

A principal motivação do presente trabalho de dissertação prendeu-se com o desenvolvimento e implementação de um sistema capaz de realizar a previsão de consumos eléctricos do dia seguinte, numa determina SE da rede de distribuição.

Durante a realização deste trabalho surgiram alguns contratempos que dificultaram a sua realização. O facto dos dados de consumo de energia eléctrica que correspondem à essência do âmbito do trabalho terem sido difíceis de obter junto da entidade responsável, foi um problema encarado com alguma preocupação inicial, bem como a dificuldade de obter os dados meteorológicos considerados necessários. Com isto, foi possível perceber a dificuldade em arranjar dados em bruto para a realização deste tipo de trabalho, o que nos leva a pensar seriamente antes de decidir avançar em definitivo para este tipo de estudo, caso contrário, poderão acontecer alguns reveses e algumas contrariedades.

Este tipo de trabalho que aborda o tema de previsão de curto prazo, é bastante importante, na medida que o conhecimento prévio dos valores de consumo de uma das SEs que compõem a rede eléctrica é um auxiliar significativo, que contribui para dotar de maior eficiência a gestão das redes. A previsão de cargas, especialmente no horizonte de curto prazo, permite às empresas de distribuição (neste caso em Portugal a EDP) operarem com maior segurança, nomeadamente, possibilita um agendamento mais eficaz de acções de manutenção, bem como aferir sobre a capacidade de alimentação de cada uma das SEs. É também relevante em situações de uma eventual necessidade de reconfiguração da rede.

Numa primeira fase foi realizado um estudo de índole teórica sobre as topologias habituais de sistemas de previsão em geral, mudando depois o foco para os sistemas de curto prazo, tendo uma especial atenção aos que recorrem a wavelets. Verificou-se que o recurso a wavelets neste tipo de sistemas de previsão está, na maioria dos casos associado à utilização de redes neuronais, como tal, tomou-se a decisão de utilizar as wavelets de uma forma diferente. Após a escolha da metodologia a utilizar, foi necessário realizar uma investigação sobre as características do consumo eléctrico associado ao ponto injector onde a SE referente ao caso de estudo está inserida. As principais conclusões que advieram desta investigação revelaram-se extremamente importante na escolha do lote das variáveis de entrada do sistema. Como resultado, as variáveis de entrada escolhidas foram: tipo de dia de semana; verificação se o dia de previsão é feriado ou não; temperatura prevista referente ao dia de previsão e aos últimos 7 dias anteriores; valores de consumo dos últimos 7 dias anteriores ao dia de previsão. Quanto ao efeito da temperatura, foi interessante constatar que a diferença entre os resultados de previsão dos algoritmos com e sem esta variável foi praticamente nulo, tendo até, o algoritmo que não utiliza os valores de temperatura atingido os melhores resultados globais de previsão.

Avaliando os dois modelos de previsão criados, os resultados demonstraram ser bastante interessantes quando comparados com os valores de previsão de consumo nacional, cujo erro se situa na ordem dos 5%. Apesar do valor do erro de previsão de consumo de potência activa e energia do presente trabalho se situar sempre abaixo dos 10%, é necessário ter em conta que a previsão a nível nacional representa um maior agregado de informação, do que uma única SE (AT/MT), representando este facto uma maior facilidade em prever o consumo, visto que a mínima oscilação de valores num universo mais reduzido tem um impacto mais relevante do que num universo mais alargado.

## 5.2 Trabalho futuro

Em relação ao trabalho futuro, existem pontos que poderão ser alvo de constante desenvolvimento de modo a serem obtidos resultados cada vez com maior precisão. Na área da previsão de consumo, o conceito “perfeição” é praticamente uma utopia, visto que isso implica uma previsão que coincida na totalidade das vezes com o que foi efectivamente verificado. Contudo, a meta será sempre tentar reduzir a diferença entre esses dois valores, de forma a considerar a previsão consistente. Uma sugestão para reduzir estas diferenças consiste em tentar procurar razões para os dias em que ocorreram consumos padrão fora do normal.



Outro ponto que se revela de extrema importância quanto ao trabalho futuro é o de estudar o modelo desenvolvido noutras SEs do sistema eléctrico, por forma a aperfeiçoar os algoritmos. Uma outra opção a realizar pode estar relacionada com a introdução de novas variáveis de entrada do modelo, como por exemplo a hora do dia.



## REFERÊNCIAS BIBLIOGRÁFICAS

- Alfares, H. K., & Nazeeruddin, M. (2002). Electric load forecasting: Literature survey and classification of methods. *International Journal of Systems Science*, 33(November), 23–34.
- Amjady, N., & Keynia, F. (2009). Short-term load forecasting of power systems by combination of wavelet transform and neuro-evolutionary algorithm. *Energy*, 34, 46–57.
- Andrade, L. C. M. de, Flauzino, R. A., & Silva, I. N. da. (2010). Sistemas fuzzy para previsão de demanda de energia elétrica no curtíssimo prazo. In *DINCON 10* (pp. 384–390).
- Andrade, G. S. (2009). *Uso de wavelets para a melhoria de desempenho de simulações numéricas usando carregamentos de pistas na indústria automotiva*. UNIVERSIDADE FEDERAL DA BAHIA.
- Baniamerian, A., Asadi, M., & Yavari, E. (2009). Recurrent wavelet network with new initialization and its application on short-term load forecasting. *EMS 2009 - UKSim 3rd European Modelling Symposium on Computer Modelling and Simulation*, 379–383.
- Benaouda, D., Murtagh, F., Starck, J. L., & Renaud, O. (2006). Wavelet-based nonlinear multiscale decomposition model for electricity load forecasting. *Neurocomputing*, 70, 139–154.
- Bonanno, F., Capizzi, G., & Sciuto, G. Lo. (2013). A Neuro Wavelet - Based Approach for Short - Term Load Forecasting in Integrated Generation Systems, 772–776.
- Božić, M., Stojanović, M., Stajić, Z., & Tasić, D. (2013). A new two-stage approach to short term electrical load forecasting. *Energies*, 6, 2130–2148.  
doi:10.3390/en6042130
- Campbell, P. R. J., & Adamson, K. (2006). Methodologies for load forecasting. In *IEEE Intelligent Systems* (pp. 800–806).

- Chaturvedi, D. K., Premdayal, S. A., & Chandiok, A. (2013). Short Term Load Forecasting using Neuro-fuzzy-Wavelet Approach. *International Journal of Computing Academic Research (IJCAR)*, 2(1), 36–48.
- Chen, Y., Luh, P. B., & Rourke, S. J. (2010). Short-term load forecasting: Similar day-based wavelet neural networks. *IEEE Transactions on Power Systems*, 25(1), 322–330. Retrieved from <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5340640>
- Coelho, B. M. M. (2012). *Classificação de Tipologia de rede da EDP Distribuição*. Faculdade de Engenharia da Universidade do Porto.
- Daubechies, I. (1990). The wavelet transform, time-frequency localization and signal analysis. *IEEE Transactions on Information Theory*, 36(5), 961–1005.
- Daubechies, I. (1996). Where do wavelets come from? A personal point of view. *Proceedings of the IEEE*, 84(4), 510–513.
- Debnath, L., & Shah, F. (2014). *Wavelet Transforms and Their Applications* (Vol. 2 edition, pp. 1–553). Springer. Retrieved from <https://books.google.com/books?id=qPuWBQAAQBAJ&pgis=1>
- EDP. (2011a). *Encontros da Ligação* (pp. 1–140).
- EDP. (2011b). *Manual de ligações à rede eléctrica do serviço público: guia técnico e logístico de boas práticas* (pp. 1–168).
- EDP. (2013). *Caracterização das Redes de Distribuição a 31 Dezembro 2013* (pp. 1–106).
- EDP - Sistema Eléctrico Português. (2015). Retrieved March 12, 2015, from <http://www.edp.pt/pt/aedp/sectordeenergia/sistemaelectricoportugues/Pages/SistElectNacional.aspx>
- ERSE - Plano de Promoção da Eficiência no Consumo de Energia Eléctrica. (2015). Retrieved March 8, 2015, from <http://www.erse.pt/pt/planodepromocaodaeficiencianoconsumoppec/Paginas/default.aspx>
- Fan, S., & Hyndman, R. J. (2012). Short-term load forecasting based on a semi-parametric additive model. *IEEE Transactions on Power Systems*, 27(August 2010), 134–141.
- Fard, A. K., & Zadeh, M. A. (2013). A hybrid method based on wavelet , ANN and ARIMA model for short-term load forecasting. *Journal of Experimental & Theoretical Artificial Intelligence*, (November), 37–41.
- Feinberg, E. a, & Genethliou, D. (2005). Load Forecasting. *Applied Mathematics for Restructured Electric Power Systems*, 269–285.

- Fernandes, P. G. M. (2012). *Modelização e análise de desempenho de redes de distribuição mistas*. Instituto Superior de Engenharia do Porto.
- Ferreira, J. C. (2009). *Utilização da Transformada de Wavelet para Detectar Variações Anormais de Frequência em Sistemas de Geração Distribuída*. Universidade Federal de Uberlândia.
- Ferreira, T. M. (2013). *Descoberta de Padrões de Consumo de Energia Elétrica*. Universidade do Minho.
- Guan, C. (2013). *Wavelet Neural Network Based Very Short-term Load Forecasting and Prediction Interval Estimation*. University of Connecticut.
- Guan, C., Luh, P. B., Coolbeth, M. a, Zhao, Y., Michel, L. D., Chen, Y., ... Rourke, S. J. (2009). Very Short-term Load Forecasting : Multilevel Wavelet Neural Networks with Data Pre-filtering. *Micro*, 1–8.
- Guirelli, C. R. (2006). *Previsão da carga de curto prazo de áreas elétricas através de técnicas de inteligência artificial*. Universidade de São Paulo.
- Hahn, H., Meyer-Nieberg, S., & Pickl, S. (2009). Electric load forecasting methods: Tools for decision making. *European Journal of Operational Research*, 199(3), 902–907.
- Hippert, H. S., Pedreira, C. E., & Souza, R. C. (2001). Neural networks for short-term load forecasting: a review and evaluation. *IEEE Transactions on Power Systems*, 16(1), 44–55.
- Kapgate, D. ., & Mohod, S. . (2013). Short Term Load Forecasting Using Hybrid Neuro Wavelet Model. *International Journal of Electronics and Communication Engineering & Technology*, 4(2), 280–289.
- Kelo, S., & Dudul, S. (2012). A wavelet Elman neural network for short-term electrical load prediction under the influence of temperature. *International Journal of Electrical Power and Energy Systems*, 43(1), 1063–1071.
- Kelo, S. M., & Dudul, S. V. (2010). Short-term load prediction with a special emphasis on weather compensation using a novel committee of wavelet recurrent neural networks and regression methods. *2010 Joint International Conference on Power Electronics, Drives and Energy Systems, PEDES 2010 and 2010 Power India*.
- Mallat, S. (1989). A theory for multiresolution signal decomposition: the wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11(7), 674–693.
- Mallat, S. (2008). *A Wavelet Tour of Signal Processing: The Sparse Way*. Retrieved from <https://www.google.pt/books?hl=pt-PT&lr=&id=5qzeLJljuLoC&pgis=1>

- MathWorks. (2015). Matching Pursuit - Command Line - MATLAB & Simulink. Retrieved March 19, 2015, from <http://www.mathworks.com/help/wavelet/ug/matching-pursuit--command-line.html#btdg96p>
- Mercado REN. (2015). Retrieved March 11, 2015, from <http://www.mercado.ren.pt/PT/Electr/Paginas/default.aspx>
- Misiti, M., Poggi, J., Misiti, Y., & Oppenheim, G. (2001). *Wavelet Toolbox For Use with MATLAB* (pp. 1–891). MathWorks.
- Misiti, M., Poggi, J., Misiti, Y., & Oppenheim, G. (2013). *Wavelet Toolbox™ User's Guide R 2013 b* (Version 4., pp. 1–625). MathWorks.
- Mourão, J. L. M. M. (2012). *Análise Estatística dos Resultados do Mercado Ibérico de Eletricidade no ano de 2012*. Faculdade de Engenharia da Universidade do Porto.
- Nava, E. (2006). *Wavelets: theory and applications*. Malaga, Espanha.
- O negócio da eletricidade em Portugal. (2015). Retrieved March 8, 2015, from <http://www.galpenenergia.com/PT/agalpenenergia/os-nossos-negocios/Gas-Power/Power/Paginas/Negocio-da-electricidade-em-Portugal.aspx>
- Pindoriya, N. M., Singh, S. N., & Singh, S. K. (2010). Forecasting of Short-Term Electric Load Using Application of Wavelets with Feed-Forward Neural Networks. *International Journal of Emerging Electric Power Systems*, 11(1), 27.
- PORDATA. (2015). PORDATA. Retrieved March 9, 2015, from <http://www.pordata.pt/>
- Previsão de consumo diário. (2015). Retrieved March 8, 2015, from <http://www.mercado.ren.pt/PT/Electr/InfoMercado/Consumo/PrevConsumo/Paginas/default.aspx>
- Reis, A. J. R., & Silva, A. P. A. Da. (2004). Aplicação da transformada wavelet discreta na previsão de carga a curto prazo via redes neurais. *Sba: Controle & Automação Sociedade Brasileira de Automatica*, 15(1), 101–108.
- Reis, A. J. R., & Silva, A. P. A. Da. (2005). Feature Extraction via Multiresolution Analysis for Short-Term Load Forecasting. *Ieee Transactions on Power Systems*, 20(1), 189–198.
- REN. (2011). *Caracterização da rede nacional de transporte para efeitos de acesso à rede em 31 de Dezembro de 2010* (pp. 1–69).
- REN. (2014a). *Caracterização da rede nacional de transporte para efeitos de acesso à rede em 31 de Dezembro de 2013* (pp. 1–71).

- REN. (2014b). *Dados Técnicos Electricidade 2013* (pp. 1–36).
- REN - Eletricidade. (2015). Retrieved March 8, 2015, from [http://www.ren.pt/pt-PT/o\\_que\\_fazemos/eletricidade/](http://www.ren.pt/pt-PT/o_que_fazemos/eletricidade/)
- Sá, D. C. S. C. (2013). *Load Forecasting on Special Days*. Faculdade de Engenharia Universidade do Porto.
- Santos, P. J. da C. (2005). *Previsão de cargas em horizonte de curto-prazo aplicada a subestações de distribuição*. Universidade de Coimbra.
- Saraiva, J. P. T. (2015). O Sistema Elétrico Nacional – Regulação e Tarifas; Perspetivas de Evolução e Desafios —. Retrieved March 8, 2015, from <http://www.inesctec.pt/cpes/noticias-eventos/nos-na-imprensa/o-sistema-eletrico-nacional-2013-regulacao-e-tarifas-perspetivas-de-evolucao-e-desafios/>
- Saraiva, J. P. T., Silva, J. L. P. P. da, & Leão, M. T. P. (2002). *Mercados de Electricidade - Regulação e Tarificação de Uso das Redes* (1<sup>a</sup> edição., pp. 1–293). FEUP Edições. Retrieved from <https://books.google.com/books?id=uQ-XeOYIRLQC&pgis=1>
- Singh, A. K., Ibraheem, Khatoon, S., Muazzam, M., & Chaturvedi, D. K. (2012). Load forecasting techniques and methodologies: A review. In *ICPCES 2012 - 2012 2nd International Conference on Power, Control and Embedded Systems* (p. 10).
- Sousa, J. M. C. de. (2013). *Caracterização horária de consumos de energia elétrica e previsão de curto prazo em mercados liberalizados*. Universidade de Coimbra.
- Strang, G., & Nguyen, T. (1996). *Wavelets and Filter Banks* (pp. 1–490). Wellesley-Cambridge Press. Retrieved from [http://books.google.com/books?id=Z76N\\_Ab5pp8C&pgis=1](http://books.google.com/books?id=Z76N_Ab5pp8C&pgis=1)
- Suganthi, L., & Samuel, A. a. (2012). Energy models for demand forecasting - A review. *Renewable and Sustainable Energy Reviews*, 16(2), 1223–1240.
- Swee, E. G. T., & Elangovan, S. (1999). Applications of symlets for denoising and load forecasting. In *Proceedings of the IEEE Signal Processing Workshop on Higher-Order Statistics. SPW-HOS '99* (pp. 165–169). IEEE Comput. Soc.
- Szeliski, R. (2009). Computer Vision : Algorithms and Applications. In *Computer Vision : Algorithms and Applications* (pp. 100–209).
- Thuillard, M. (2001). *Wavelets in Soft Computing*. World Scientific Publishing Co.Pte. Ltd. Retrieved from <http://www.google.pt/books?hl=pt-PT&lr=&id=9fheTNfmdBkC&pgis=1>
- Zhang, Q., & Benveniste, A. (1992). Wavelet networks. *IEEE Transactions on Neural Networks / a Publication of the IEEE Neural Networks Council*, 3(6), 889–98.

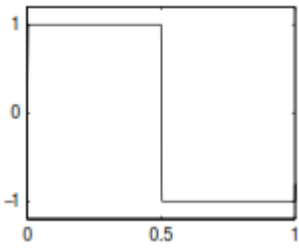
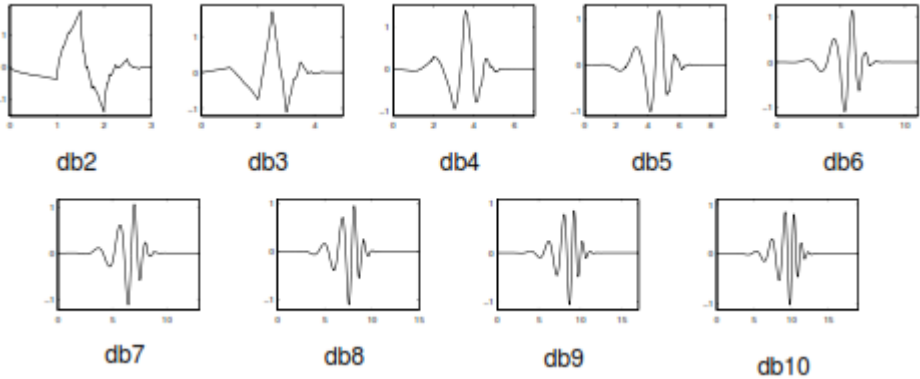
Zhao, Y., Luh, P. B., Bomgardner, C., & Beerel, G. H. (2009). Short-term load forecasting: Multi-level wavelet neural networks with holiday corrections. *2009 IEEE Power and Energy Society General Meeting, PES '09*, 1–7.

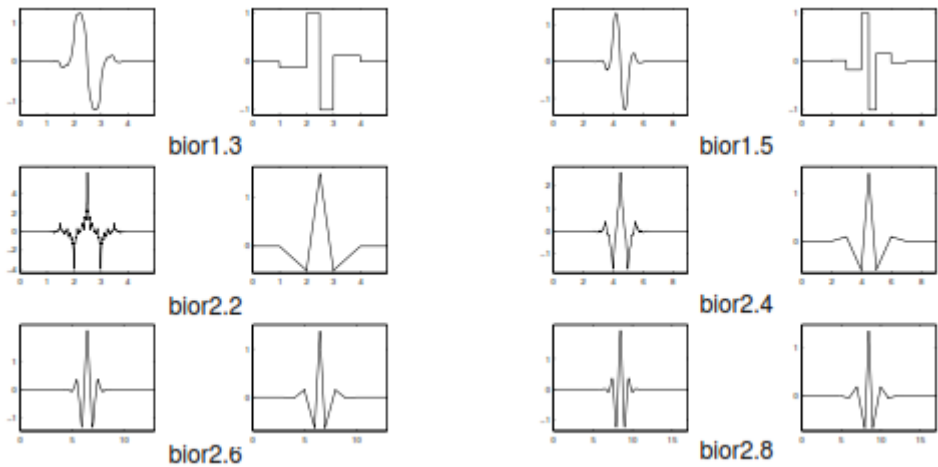
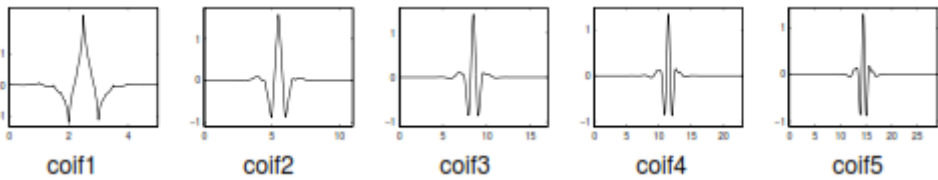
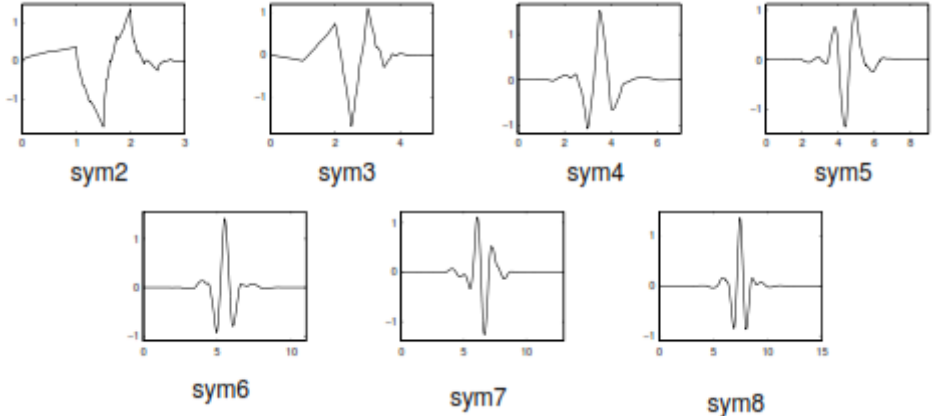
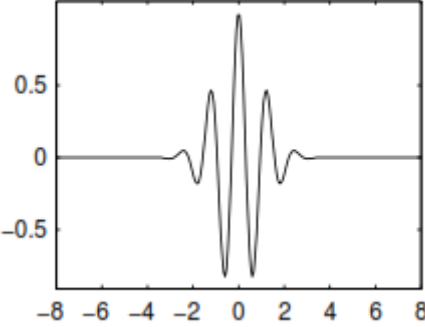


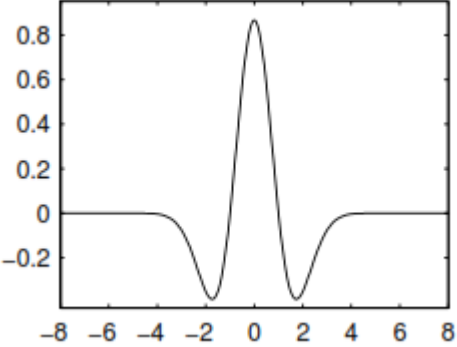
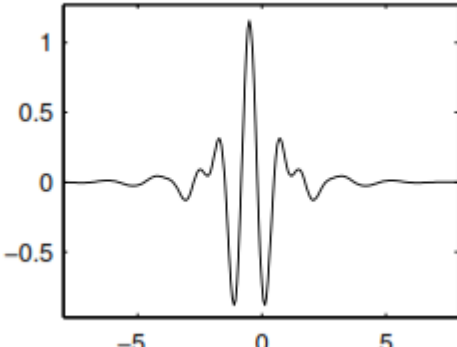
## ANEXOS

### Anexo 1: Ilustração dos tipos de Wavelets

Todas as imagens são retiradas de (Misiti et al., 2001).

Família Wavelet	Representação Gráfica
Harr	
Daubechies	

<b>Biorthogonal</b>	
<b>Coiflets</b>	
<b>Symlets</b>	
<b>Morlet</b>	

<b>Mexican Hat</b>	
<b>Meyer</b>	

## Anexo 2: Código Matlab da TWD

```
[c_dia_d,l_dia_d]=wavedec(dia_d,3,'db2'); %TWD nivel 3 utilizando db2

[cD1_dia_d, cD2_dia_d, cD3_dia_d] = detcoef(c_dia_d,l_dia_d,[1 2 3]);
cA3_dia_d= appcoef(c_dia_d,l_dia_d,'db2',3); %coeficiente de 3ª ordem
cA2_dia_d= appcoef(c_dia_d,l_dia_d,'db2',2); %coeficiente de 2ª ordem
cA1_dia_d= appcoef(c_dia_d,l_dia_d,'db2',1); %coeficiente de 1ª ordem
```

## Anexo 3: Código Matlab da aproximação de Wavelet

```
dictionary = {'db4',2}; %definição do tipo de wavelet a utilizar

[mpdict,nbvect] = wmpdictionary(length(dia_d),'lstcpt',dictionary);
[y,r,coef,iopt,qual] = wmpalg('OMP',dia_d,mpdict,'itermax',25);
```

## Anexo 4: Código Matlab do algoritmo de previsão Max temperatura

```
M=([y7 y6 y5 y4 y3])';
```

```
mat_temp=[temp_d7 temp_d6 temp_d5 temp_d4 temp_d3];
mat_errot=[abs(temp_d-temp_d7) abs(temp_d-temp_d6) abs(temp_d-
temp_d5) abs(temp_d-temp_d4) abs(temp_d-temp_d3)];
media=(mean(M))';
mat_errol=[(media-y7) (media-y6) (media-y5) (media-y4) (media-y3)];
media_mat_errol=mean(mat_errol);
[valor_max, indice_max]=max(mat_errot);
[valor_min, indice_min]=min(mat_errot);
dif_max_min=valor_max-valor_min;

previsao_maxtemp=media+media_mat_errol(indice_max); %previsão com o
máximo de temperatura
```

## Anexo 5: Código Matlab do algoritmo de previsão Min temperatura

```
M=[y7 y6 y5 y4 y3]';
mat_temp=[temp_d7 temp_d6 temp_d5 temp_d4 temp_d3];
mat_errot=[abs(temp_d-temp_d7) abs(temp_d-temp_d6) abs(temp_d-
temp_d5) abs(temp_d-temp_d4) abs(temp_d-temp_d3)];
media=(mean(M))';
mat_errol=[(media-y7) (media-y6) (media-y5) (media-y4) (media-y3)];
media_mat_errol=mean(mat_errol);
[valor_min, indice_min]=min(mat_errot);

previsao_mintemp=media+media_mat_errol(indice_min); %previsão com o
mínimo de temperatura
```

## Anexo 6: Código Matlab do algoritmo de previsão Max\_Min temperatura

```
M=[y7 y6 y5 y4 y3]';
mat_temp=[temp_d7 temp_d6 temp_d5 temp_d4 temp_d3];
mat_errot=[abs(temp_d-temp_d7) abs(temp_d-temp_d6) abs(temp_d-
temp_d5) abs(temp_d-temp_d4) abs(temp_d-temp_d3)];
media=(mean(M))';
mat_errol=[(media-y7) (media-y6) (media-y5) (media-y4) (media-y3)];
media_mat_errol=mean(mat_errol);
[valor_max, indice_max]=max(mat_errot);
[valor_min, indice_min]=min(mat_errot);
dif_max_min=valor_max-valor_min;

previsao_semtemp=media; %previsão só com a média
previsao_maxtemp=media+media_mat_errol(indice_max); %previsão com o
máximo de temperatura
previsao_mintemp=media+media_mat_errol(indice_min); %previsão com o
mínimo de temperatura
previ-
sao_maxmintemp=media+((media_mat_errol(indice_max)+media_mat_errol(indice
_min))/2); %previsão com o máximo e mínimo de temperatura
```